

VŠB - Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky

BAKALÁŘSKÁ PRÁCE

VŠB - Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Tvorba a kvantitativní hodnocení hypnogramů

Creation and quantitative evaluation of hypnograms

VŠB - Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Zadání bakalářské práce

Student: **Klaudia Ježíková**
Studijní program: **B2649 Elektrotechnika**
Studijní obor: **3901R039 Biomedicínský technik**
Téma: **Tvorba a kvantitativní hodnocení hypnogramů**
Creation and Quantitative Evaluation of Hypnograms
Jazyk vypracování: **čeština**

Zásady pro vypracování:

1. Rozbor problematiky snímání EEG, spánkového EEG, polysomnografie, metod tvorby a hodnocení hypnogramů.
2. Návrh a realizace metody pro tvorbu hypnogramů.
3. Návrh a realizace metody pro hodnocení hypnogramů.
4. Zhodnocení dosažených výsledků.

Seznam doporučené odborné literatury:


- [1] MOHYLOVÁ, Jitka a Vladimír KRAJČA. *Zpracování biologických signálů*. Vyd. 1. Ostrava: VŠB - Technická univerzita Ostrava, 2007, 1 CD-R. ISBN 978-80-248-1491-9.
- [2] PENHAKER, Marek a Martin AUGUSTYNEK. *Zdravotnické elektrické přístroje 1*. 1. vyd. Ostrava: VŠB - Technická univerzita Ostrava, 2013, 411 s. ISBN 978-80-248-3107-7.
- [3] PENHAKER, Marek. *Práce v prostředí MATLAB*. [CD ROM] První vydání, Ostrava: VŠB - Technická univerzita Ostrava, 2007, 364 stran. ISBN 978-80-248-1559-6.
- [4] MATLAB - Dostupné manuály a literatura.
- [5] NEVŘIVA, Pavel. *Analýza signálů a soustav* [záznam a]. 1. vyd. Praha: BEN - technická literatura, 2000, 671 s. ISBN 80-7300-004-0.


Formální náležitosti a rozsah bakalářské práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.


Vedoucí bakalářské práce: **Ing. Radek Hrabuška**

Datum zadání: 01.09.2015

Datum odevzdání: 28.04.2017

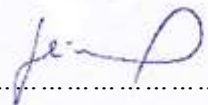

doc. Ing. Jiří Koziolek, Ph.D.
vedoucí katedry




prof. RNDr. Václav Snášel, CSc.
děkan fakulty

Prehlásenie

Čestne prehlasujem, že som predloženú bakalársku prácu vypracovala samostatne pod vedením vedúceho práce, na základe konzultácií a štúdia odbornej literatúry . Všetky použité literárne pramene a publikácie, z ktorých som čerpala, som uviedla na príslušnom mieste.



.....
Klaudia Ježíková

V Ostrave dňa 30. júna 2017

Pod'akovanie

Týmto by som sa rada poďakovala Ing. Radkovi Hrabuškovi za odbornú pomoc a konzultácie, ktoré mi poskytol pri vypracovaní bakalárskej práce, za cenné rady a informácie a v neposlednom rade za ochotu. Osobitné poďakovanie patrí mojej rodine a priateľom za podporu a pochopenie.

Abstrakt

Účelom tejto práce je návrh a realizácia metódy pre vytvorenie hypnogramu. Druhá časť práce venuje pozornosť návrhu a spracovaniu metódy pre kvantitatívne hodnotenie spánkového diagramu. Celý program je vypracovaný v programovacom jazyku matlab. Úvodné časti bakalárskej práce rozoberajú základy fyziológie spánku, spánkové cykly a hypnogram. Práca poskytuje i stručný popis použitých algoritmov pre klasifikáciu spánkových fáz a metód pre hodnotenie kvality spánku na základe kvantitatívneho vyhodnotenia hypnogramu. Ďalšie časti popisujú spracovanie polysomnografických dát v programe matlab, tréning a testovanie jednotlivých algoritmov pri klasifikovaní hypnogramu. Posledné časti sú venované návrhu a realizácii hodnotenia kvality spánku u použitých hypnogramov na báze automatického výpočtu kvantitatívnych parametrov, a následne porovnávania vypočítaných hodnôt (so stanovenými optimálnymi hodnotami). Tieto komparácie sú realizované podľa pravidiel R&K (a novších AASM).

Kľúčové slová

EEG, Polysomnografia, REM, Non-REM, Spánkový diagram, SVM, kNN, Rozhodovací strom.

Abstract

The purpose of this bachelor thesis is to design and implement a method for creating a hypnogram. The second part of this thesis is dedicated to the design and processing the method for quantitative evaluation of the hypnograms. The entire program is written in matlab programming language. The introductory parts of the bachelor thesis analyze the basics of sleep physiology, sleep cycles and hypnogram. The thesis also provides a brief description of used algorithms for classification of the sleep phases and the methods for evaluation of the sleep quality based on the quantitative hypnogram evaluation. The following parts describe the processing of polysomnographic data in the matlab program, training and testing of the particular algorithms at the hypnogram classification. The final parts are dedicated to the design and implementation of the sleep quality evaluation of the used hypnograms, based on the automated calculation of quantitative parameters and subsequently the comparison of the calculated values (with the optimal values). These comparisons are performed according to the R&K manual (and later AASM).

Keywords

EEG, Polysomnography, REM, Non-REM, Hypnogram, SVM, kNN, Complex tree.

Obsah

ZOZNAM POUŽITÝCH SYMBOLOV A SKRATIEK.....	5
ZOZNAM ILUSTRÁCIÍ	6
ZOZNAM TABULIEK	9
ÚVOD	11
1 ELEKTROENCEFALOGRAFIA.....	12
1.1 EEG ELEKTRÓDY	12
1.2 EEG ZVODY.....	13
1.3 ELEKTROENCEFALOGRAF	14
1.4 ELEKTROENCEFALOGRAM	15
1.5 ZÁKLADNÉ RYTMY EEG.....	15
2 POLYSOMNOGRAFIA	17
2.1 ELEKTROMYOGRAFIA	17
2.2 ELEKTROOKULOGRAFIA	17
2.3 POLYSOMNOGRAFICKÁ TECHNIKA	18
3 ŠTRUKTÚRA SPÁNKU	20
3.1 SPÁNKOVÉ CYKLY	20
3.1.1 REM spánok	20
3.1.2 NonREM spánok.....	20
4 HYPNOGRAM	22
4.1 KLASIFIKÁCIA HYPNOGRAMU	22
4.1.1 Jednovrstvové a mnohovrstvové umelé neurónové siete	22
4.1.2 Rozhodovací strom	23
4.1.3 kNN klasifikátor.....	23
4.1.4 SVM klasifikátor.....	24
5 HODNOTENIE KVALITY SPÁNKU.....	28
6 SOFTWARE	29
6.1 MATLAB	29
6.1.1 VSTUPNÉ DÁTA.....	29
6.1.2 VERIFIKÁCIA DÁT	31
6.1.1 EXTRAKCIA PRÍZNAKOV	32
6.1.1.1 SEGMENTÁCIA	32
6.1.2 KLASIFIKÁCIA.....	34
6.1.2.1 TRÉNOVANIE KLASIFIKÁCIE	35
6.1.2.2 TESTOVANIE KLASIFIKÁCIE	47
7 VYHODNOTENIE HYPNOGRAMU	56
8 ZHRNUTIE DOSIAHNUTÝCH VÝSLEDKOV	60
ZÁVER.....	61
LITERATÚRA	62
POUŽITÉ ZDROJE OBRÁZKOV	64

ZOZNAM PRÍLOH	I
----------------------------	----------

Zoznam použitých symbolov a skratiek

AASM	American Academy of Sleep Medicine (americká akadémia spánkovej medicíny)
DP	dolnoprepustný filter
Edf	European data format (formát polysomnografických dát, vrátane hypnogramov)
EEG	elektroencefalografia
EKG	elektrokardiografia
EMG	elektromyografia
EOG	elektrookulografia
FFT	Fast Fourier Transformation (rýchla Fourierova transformácia)
Fpz – Cz	elektroencefalografický kanál
HP	hornoprepustný filter
kNN	k Nearest Neighbour (klasifikačný algoritmus podľa najbližších susedov)
N1	spánková fáza NonREM1 podľa AASM
N2	spánková fáza NonREM2 podľa AASM
N3 (S1 + S2)	spánková fáza NonREM3 + NonREM4 podľa AASM
NonREM	non-rapid eye movement (spánková fáza)
Obs/sec	pozorovania za sekundu (u rýchlosti tréningu algoritmu)
Overfitting	preučenie algoritmu
PSD	power spectral density (výkonová spektrálna hustota)
PSG	polysomnografia
Pz – Oz	elektroencefalografický kanál
R	REM fáza
REM	rapid eye movement (spánková fáza, rýchle pohyby očí)
R&K	Rechtschaffen and Kales (manuál spánkovej medicíny podľa Rechtschaffena a Kalesa)
S1, 1	spánková fáza NonREM1 podľa R&K
S2, 2	spánková fáza NonREM2 podľa R&K
S3, 3	spánková fáza NonREM3 podľa R&K
S4, 4	spánková fáza NonREM4 podľa R&K
SWS	slow wave sleep (pomalé delta vlny u spánku – N3, N4)
SVM	support vector machine (klasifikačný algoritmus podporných vektorov)
UNS	klasifikačná metóda, umelé neurónové siete
W	fáza vigility
Wake, 0	fáza vigility podľa R&K

Zoznam ilustrácii

Obr. 1: EEG čiapka	12
Obr. 2: Rozloženie EEG elektród podľa systému 10/20 (A - pohľad z ľavej strany, B - pohľad zhora)	13
Obr. 3: Základné frekvenčné hladiny mozgu – EEG rytmy	16
Obr. 4: Umiestnenie EMG elektród	17
Obr. 5: Rozmiestnenie EOG elektród	18
Obr. 6: Biologické artefakty pri EEG vyšetrení	18
Obr. 7: Technické artefakty	19
Obr. 8: Princíp SVM	24
Obr. 9: Hľadanie optimálnej separovateľnej roviny. Body na okrajoch pásma sú hľadané podporné vektory	25
Obr. 10: Matematická formulácia SVM	26
Obr. 11: Prostredie matlab	29
Obr. 12 Test komplexity – výpis do Command Window	31
Obr. 13 Test komplexity – výpis do Command Window	31
Obr. 14: Výpočet PSD v matlabe	33
Obr. 15 Výkonová spektrálna hustota pre EEG signál (kanál Fpz – Cz) pre SC4002E0	33
Obr. 16 Výkonová spektrálna hustota pre EEG signál (kanál Pz – Oz) pre SC4002E0	34
Obr. 17: Započatie novej klasifikácie – import feature vektoru	34
Obr. 18: Trénovací vektor	35
Obr. 19: Extrakcia feature vektoru v LEARNING TOOLBOX	35
Obr. 20: Feature vektor v matlabe	35
Obr. 21: Navolenie validačnej metódy	36
Obr. 22: Prevedenie dát do tabuľkového formátu	36
Obr. 23: Rozloženie dát (jednotlivé triedy 0 – 9 sú farebne odlíšené podľa čestnosti výskytu) ..	37
Obr. 24: SVM model 1 (na obrázku sú krížikom zaznačené nesprávne klasifikované body)	37
Obr. 25: SVM model 1 – Confusion matrix, zobrazujúca počet pozorovaní klasifikovaných tried	38
Obr. 26: Confusion matrix – zobrazenie skutočne pozitívneho a falošne negatívneho pomeru lineárnej SVM klasifikácie	38
Obr. 27: ROC krivka pre lineárny SVM klasifikátor (s porovnávacou – pozitívnu triedou 0) ..	39
Obr. 28: Export trénovaného modelu	40
Obr. 29: SVM model 2 (na obrázku je možné vidieť nesprávne klasifikované body označené krížikom)	40
Obr. 30: SVM model 2 – Confusion matrix, zobrazujúca počet pozorovaní klasifikovaných spánkových úrovní	41

Obr. 31: Confusion matrix – zobrazenie skutočne pozitívneho a falošne negatívneho pomeru kvadratickej SVM klasifikácie	41
Obr. 32: SVM model 3 (na obrázku sú krížikom zaznačené nesprávne klasifikované body).....	42
Obr. 33: SVM model 3 – Confusion matrix, zobrazujúca počet pozorovaní klasifikovaných tried	42
Obr. 34: Confusion matrix – zobrazenie skutočne pozitívneho a falošne negatívneho pomeru kubickej SVM klasifikácie.....	43
Obr. 35: Complex Tree model (obrázok vpravo znázorňuje nesprávne klasifikované body).....	43
Obr. 36: Complex Tree model – Confusion matrix, zobrazujúca počet pozorovaní klasifikovaných tried	44
Obr. 37: Confusion matrix – zobrazenie skutočne pozitívneho a falošne negatívneho pomeru Complex Tree klasifikácie	44
Obr. 38: kNN model (na obrázku sú krížikom zaznačené nesprávne klasifikované body).....	45
Obr. 39: kNN model – Confusion matrix, zobrazujúca počet pozorovaní klasifikovaných tried	45
Obr. 40: Confusion matrix – zobrazenie skutočne pozitívneho a falošne negatívneho pomeru kNN klasifikácie	46
Obr. 41: Príkaz v matlabe pre testovanie lineárnej SVM klasifikácie	47
Obr. 42: Graf zobrazujúci pôvodný (nameraný) hypnogram a nový (klasifikovaný) hypnogram, vygenerovaný matlabom	47
Obr. 43: Graf zobrazujúci pôvodný (modrý) a klasifikovaný (červený) hypnogram, vygenerovaný v matlabe (červené miesta označujú nezhodu medzi nameraným a klasifikovaným hypnogramom)	48
Obr. 44: Príkaz v matlabe pre testovanie kvadratickej SVM klasifikácie.....	49
Obr. 45: Graf zobrazujúci pôvodný (nameraný) hypnogram a nový (klasifikovaný) hypnogram, vygenerovaný matlabom	49
Obr. 46: Graf zobrazujúci pôvodný (modrý) a klasifikovaný (červený) hypnogram, vygenerovaný v matlabe (červené miesta označujú nezhodu medzi nameraným a klasifikovaným hypnogramom)	49
Obr. 47: Príkaz v matlabe pre testovanie kubickej SVM klasifikácie.....	50
Obr. 48: Graf zobrazujúci pôvodný (nameraný) hypnogram a nový (klasifikovaný) hypnogram, vygenerovaný matlabom	50
Obr. 49: Graf zobrazujúci pôvodný (modrý) a nový (červený) hypnogram, vygenerovaný v matlabe (červené miesta označujú nezhodu medzi nameraným a klasifikovaným hypnogramom)	51
Obr. 50: Príkaz v matlabe pre testovanie Complex Tree klasifikácie	52
Obr. 51: Graf zobrazujúci pôvodný (nameraný) hypnogram a nový (klasifikovaný) hypnogram, vygenerovaný matlabom	52
Obr. 52: Graf zobrazujúci pôvodný (modrý) a nový (červený) hypnogram, vygenerovaný v matlabe (červené miesta označujú nezhodu medzi nameraným a klasifikovaným hypnogramom)	52
Obr. 53: Príkaz v matlabe pre testovanie kNN klasifikácie	53

Obr. 54: Graf zobrazujúci pôvodný(nameraný) hypnogram a nový (klasifikovaný) hypnogram, vygenerovaný matlabom	53
Obr. 55: Graf zobrazujúci pôvodný a klasifikovaný hypnogram	53
Obr. 56: Graf zobrazujúci zastúpenie celkového spánku v závislosti na dĺžke hypnogramu (SC4002E0)	56
Obr. 57: Výpočet celkovej doby spánku (hod).....	56
Obr. 58: Výpočty pre celkový podiel REM / NonREM v hypnograme	57
Obr. 59: Porovnanie optimálnej a vypočítanej hodnoty REMU pomocou funkcie ismember	57

Zoznam tabuliek

Tab. 1: Frekvencie jednotlivých mozgových aktivít	15
Tab. 2: Porovnanie jednotlivých klasifikátorov	27
Tab. 3: Databáza použitých záznamov pre tvorbu spánkového diagramu	30
Tab. 4: Overenie dĺžky záznamu.....	32
Tab. 5: Porovnanie trénovaných klasifikátorov z hľadiska presnosti, rýchlosti a doby tréovania	46
Tab. 6: Úspešnosť klasifikácie jednotlivých tried u lineárnej SVM	48
Tab. 7: Úspešnosť klasifikácie jednotlivých tried u kvadratickej SVM.....	50
Tab. 8: Úspešnosť klasifikácie jednotlivých tried u kubickej SVM	51
Tab. 9: Úspešnosť klasifikácie jednotlivých tried u Fine kNN	54
Tab. 10: Počet jednotlivých epoch nameraného a klasifikovaného hypnogramu	54
Tab. 11: Úspešnosť klasifikácie jednotlivých klasifikátorov	55
Tab. 12: Úspešnosť klasifikácie jednotlivých klasifikátorov	55
Tab. 13: Porovnanie vypočítaných a optimálnych hodnôt parametrov hypnogramu (SC4002E0)	57
Tab. 14: Parametre hypnogramu (SC4002E0)	57
Tab. 15: Porovnanie vypočítaných a optimálnych hodnôt parametrov hypnogramu (SC4012E0)	58
Tab. 16: Parametre hypnogramu (SC4012E0)	58
Tab. 17: Porovnanie vypočítaných a optimálnych hodnôt parametrov hypnogramu (SC4112E0)	58
Tab. 18: Parametre hypnogramu (SC4112E0)	59
Tab. 20: Porovnanie dĺžky prvého spánkového cyklu hypnogramu	59

Úvod

Ľudský spánok je dôležitý ako z hľadiska fyzického odpočinku, tak i pre psychickú pohodu a relax. Je základnou biologickou potrebou pre ľudského jedinca. Preto je nevyhnutné neustále vyvíjať a spracovávať riešenia pre analýzu spánku a jeho hodnotiace faktory, čo je v súčasnej dobe veľkým prínosom pre diagnostické riešenie spánkových porúch. Využíva sa najnovších metód, ktoré poskytujú možnosti ako najprecíznejšie vytvoriť obraz spánku spiaceho na podklade fyziologického stavu pacienta.

Existuje mnoho klasifikačných metód, ktoré umožňujú správnu klasifikáciu spánkového diagramu. Cieľom tejto práce je klasifikovanie spánkového hypnogramu a vyhodnotenie spánku pomocou hypnogramu. Teoretická časť rozoberá problematiku snímania EEG, spánkového EEG a polysomnografie, spánkových cyklov a hypnogramu. Ďalšie kapitoly popisujú použité algoritmy pre klasifikáciu hypnogramu a hodnotiace metódy.

Praktická časť tvorí najrozsiahlejšiu časť práce. Je rozdelená do dvoch dielov. Prvá časť je venovaná realizácii hypnogramu, ktorého úlohou je klasifikácia jednotlivých spánkových úrovní. Hlavná kapitola sa ďalej člení na popis programového prostredia, v ktorom bude prevedená celá klasifikácia hypnogramu a jeho vyhodnotenie. Ďalej sa zaoberá rozborom vstupných dát, zadávaných do klasifikátoru, segmentáciou signálov a klasifikáciou hypnogramu

Klasifikácia popisuje aplikovaný TOOLBOX, v ktorom bude prevedený proces učenia. Súčasťou klasifikácie je tréning zvoľeného algoritmu a testovanie daného použitého tréningového modelu pre jednotlivé typy klasifikácie.

Druhá časť popisuje kvantitatívne vyhodnotenie hypnogramu na základe troch spánkových kritérií, ktoré ovplyvňujú kvalitu spánku spiaceho.

Posledná kapitola popisuje zhodnotenie úspešnosti klasifikácie jednotlivých klasifikátorov a porovnáva kvalitu spánku podľa vypočítaných hodnôt parametrov hypnogramu.

1 Elektroencefalografia

Elektroencefalografia je diagnostická metóda, ktorej účelom je snímanie a zaznamenávanie spontánnej elektrickej aktivity mozgu. Táto vyšetrovacia metóda sa používa v neurológii a ďalších klinických a chirurgických odvetviach. EEG umožňuje snímať invazívne, teda zaznamenávanie signálov prostredníctvom pod povrchových ihlových elektród a neinvazívne tak, že signály sú zachytené z povrchu hlavy povrchovými elektródami.

Snímať môžeme z povrchu mozgovej kôry – elektrokortikografia (ECoG). Veľmi populárna je videoelektroencefalografia (video – EEG) s využitím videokamery. Záznam elektrickej aktivity mozgu nazývame elektroencefalogram; v prípade snímania mozgovej kôry ide o elektrokortikogram, vyhotovený elektroencefalografom. Elektrokortikografia poskytuje lepšiu lokalizáciu zdroja patologického EEG (epileptické ložisko), pretože sa sníma na otvorenej lebke.

Využitie elektroencefalografického vyšetrenia spočíva v určení neurologických či psychických porúch, významným využitím je diagnostika epilepsie a určenie hĺbky narkózy.

1.1 EEG elektródy

EEG elektródy zaisťujú prenos elektrickej aktivity z mozgu do zosilňovača EEG prístroja. Pri výrobe sa najčastejšie uplatňuje striebro potiahnuté vrstvou chloridu strieborného a roztok chloridu strieborného. Pre rozmiestnenie elektród sa používa systém 10/20 – používajú sa gumové sieťky (alebo čiapky) s diskovitými elektródami s priemerom asi 7 – 10 mm obalené tkanivom, do ktorej je napustený vodivý gél. Prívody sú vyvedené jedným spoločným káblom von z čiapky. Elektródy sú umiestnené na povrchu hlavy.



Obr. 1: EEG čiapka [6]

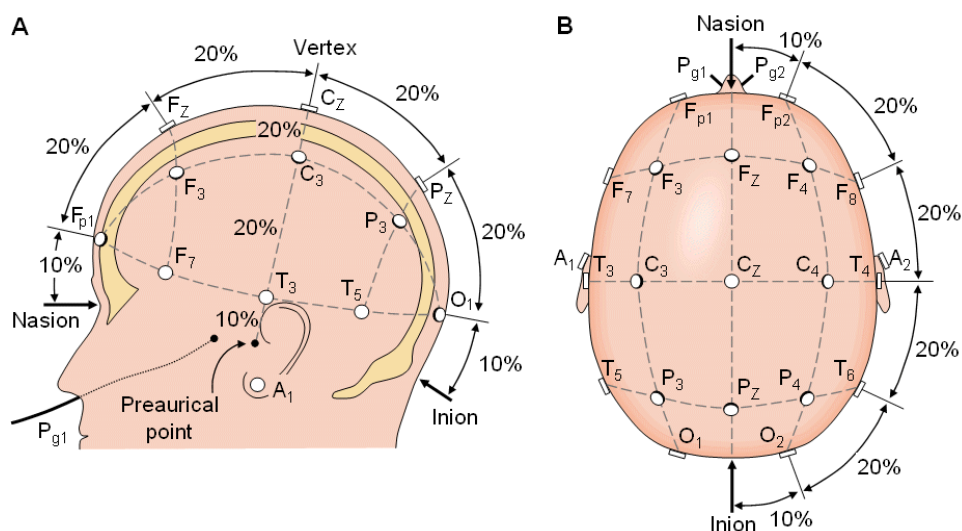
Okrem týchto rozlišujeme aj vpichové pod povrchové elektródy s kovovým hrotom, tvorené chirurgickou oceľou a platinou. Ide o elektródy, ktoré sa zavádzajú pod kožu (pri operácii otvorenej lebky, prípadne k implantácii prípravnej operácie – stripy a gridy). V súčasnosti sa veľmi nepoužívajú pre bolesť pri zavedení kovového hrotu pod lebku, možnosť prenosu infekcie. Nevýhodou je tiež vysoká impedancia na malú plochu kontaktu. V porovnaní s povrchovými elektródami je veľkou výhodou presnosť umiestnenia elektród u pod povrchových elektród.

Pri elektrokortikoencefalografii rozlišujeme implantované elektródové stripy alebo gridy, ohybné silikónové podložky (v prípade stripov ide o prúžok, na ktorom leží rada elektród, gridy tvoria matice elektród). Na ich povrchu sa nachádzajú oceľové alebo platinové elektródy s malým priemerom 3 – 4 mm. Vodiče každej rady elektród sú vyvedené jedným spoločným káblom, na konci ktorého je umiestnený konektor.

Pri operácii sa používajú najčastejšie oceľové elektródy (na konci pokryté tkanivom, obaleným v elektrolyte), polohované prostredníctvom kovového rámu, ktorý je situovaný nad otvorenou lebkou.

1.2 EEG zvody

Pre elektroencefalografické zvody platí použitie systému rozloženia elektród 10/20. Ide o rozmiestnenie elektród vo vzdialenosti 10 % a 20 %. Využíva sa pritom 21 elektród, z toho dve vymedzujú referenčnú oblasť. Elektródy sú umiestnené na ušných lalokoch (dostatočne vzdialených od ostatných elektród). Zvyšných 19 sa nachádza na lebke – umiestnenie elektródy súvisí s názvom časti lebky. Značíme takým spôsobom, že čísla označujú hemisféru (párne číslo náleží pravej hemisfére, naopak, ľavej hemisfére prislúcha nepárne číslo), písmeno indikuje lebečnú oblasť. Rozlišujeme frontálnu (prednú) – F, frontopolárnu (prednú, v okolí pomyselného pólu) – F_p, centrálnu (strednú) – C, parietálnu (temennú) – P, temporálnu (spánkovú) – T a okcipitálnu (záhlavnú) – O oblasť. Referenčné elektródy zaznačujeme A₁ (na ľavom ušnom laloku) a A₂ (na pravom ušnom laloku).



Obr. 2: Rozloženie EEG elektród podľa systému 10/20 (A - pohľad z ľavej strany, B - pohľad zhora) [7]

1.3 Elektroencefalograf

U EEG prístroja rozlišujeme 2 časti. Jednou z nich je headbox, ktorého funkcia spočíva v pripojení elektród. Pre úspešnosť vyšetrenia je nevyhnuté jeho umiestnenie v tesnej blízkosti hlavy pacienta, pre zamedzenie rušivých vplyvov.

Naopak, samotný elektroencefalograf je lokalizovaný ďalej od pacienta. Vďaka číslicovému spracovaniu signálu sme schopní previesť počítačovú analýzu EEG, ktorej výsledkom je záznam vyhotovený tlačiarňou.

V prípade bipolárneho snímania predstavuje zvod 2 susedné elektródy. Zvyčajne sa využíva 16-tich zvodov, a teda 16 kanálov. Rozvoj v oblasti číslicovej techniky umožnil prenášanie predspracovania a vzorkovania do headboxu, v porovnaní s klasickými EEG, ktoré využívali analógový prenos medzi headboxom a prístrojom. Tým sa obmedzili rušivé vplyvy u analógového prenosu a zväčšil sa pomer medzi signálom a šumom. Pre vzorkovanie je v súčasnosti používaný separátny A/D prevodník s vysokým rozlíšením. Pre zvýšenie bezpečnosti pacienta je vhodné zabezpečiť spojenie medzi headboxom a hlavnou časťou EEG prostredníctvom optického kábla.

Bežne používané zvody u EEG sú unipolárne, signály iných zapojení sa počítajú pomocou softwaru, ktorým analyzujeme EEG. Zloženie kanálu unipolárnych zvodov predstavuje vstupný predzosilňovač s diferenčným vstupom (ide o prístrojový zosilňovač pri dostatočne veľkom vstupnom odpore, rádovo stovky M Ω s pevne nastaveným malým zosilnením a premenným zosilnením), za ním sa radí filter typu pásmová priepasť, ktorej funkciou je odfiltrovanie jednosmernej zložky. Dôležitosť sa kladie taktiež na odfiltrovanie pomaly meniacej sa zložky, ktorej vznik je podmienený vplyvom polčlánkového napätia na elektróde. Obmedzenie frekvencií zhora zapríčiňuje, že pôsobí ako antialiasingový filter. Používajú sa aktívne filtre o nižších rádoch, kde sú frekvencie pevne dané. Úplnú filtráciu s nastaviteľným horným a dolným kmitočtom realizujeme digitálne za A/D prevodníkom. Kanál ďalej obsahuje zdroje napäťových kalibračných impulzov, zdroje napätí pre test impedancie elektród, zosilňovač s nastaviteľným zosilnením a A/D prevodník (najčastejšie sa používa 24-bitový pri bežnej vzorkovacej frekvencii 256 Hz; u signálov evokovaných potenciálov so vzorkovacou frekvenciou až 6 kHz) pre každý kanál, ktorý pracuje v režime predspracovania EEG signálu (predstavuje elektródu pripojenú na neinvertujúci vstup predzosilňovača, invertujúci vstup a uzemnená svorka je spojená so zemou unipolárnych zvodov), kalibrácie (zdroj kalibračného napätia sa pripája na neinvertujúci vstup, pričom elektróda je odpojená od predzosilňovača, kalibračné napätie možno meniť v rozsahu 5 μ V – 1 mV pri použití jedného zdroja kalibračného napätia pre každý kanál k dosiahnutiu rovnakého nastavenia pre všetky kanály), zdroja napätia pre test impedancie elektród a meraní napätia pri teste impedancie elektród. EEG poskytuje taktiež možnosť snímania, záznamu a spracovania evokovaných potenciálov. Pri ich spracovaní je nutná vyššia frekvencia než u bežného EEG. Medzi rozšírené funkcie EEG patrí jednoduché prepínanie medzi unipolárnymi a bipolárnymi zvodmi a ich konfiguráciami, nastavenie preneseného frekvenčného pásma, nastavenie zosilnenia na každom kanále, nastavenie rýchlosti záznamu, kalibráciu kanálov zdrojom kalibračného napätia, záznam časových značiek, zápis komentárov a udalostí, kontrolovanie kontaktu elektród s pokožkou a zapisovanie nastavených parametrov snímania. Pre záznam EEG sa používajú unipolárne zvody, pre zaznamenávanie EKG, EMG a ďalších sú využívané bipolárne a unipolárne polygrafické zvody. Dnešné elektroencefalografy obsahujú 92 až 192 EEG kanálov.

1.4 Elektroencefalogram

Elektroencefalogram vzniká súčinnosťou neurónov thalamu a kortexu, pričom thalamus slúži ako generátor impulzov. Elektrická aktivita synaptodendritických membrán vo vrstvách na povrchu kortexu predstavuje zdroj EEG. EEG signál charakterizujeme ako rytmický signál sínusového tvaru. Špičkové napätie EEG signálu, snímanom na povrchu, hraničí v rozmedzí 20 – 300 μV . U vyšetrení sa využíva frekvenčné pásmo v rozsahu 0,5 – 30 Hz. Základnou jednotkou EEG je grafoelement, kde rozlišujeme hroty a vlny. U EEG sa vyskytujú v podobe pomalej vlny, ostrej vlny, komplexu hrotu... V prípade hrotu ide o prechodný jav, ktorý sa odlišuje od pozadia EEG, môže byť patologického pôvodu.

1.5 Základné rytmy EEG

Tab. 1: Frekvencie jednotlivých mozgových aktivít


Základné rytmy EEG				
	Alfa	Beta	Theta	Delta
Frekvenčné pásmo (Hz)	8 – 13,5	14 – 30	4 – 7,5	0,5 – 3,5
Amplitúda signálu (μV)	30 – 100	2 – 20	15 – 25	75 – 150

Jednoduchú aktivitu mozgu vyjadrujeme pomocou štyroch základných frekvenčných hladín. Základným rytmom popisujeme **alfa aktivitu**, ktorá sa určuje nad oblasťou záhlavia. Alfa aktivitu pozorujeme za fyziologického stavu, môže sa však objaviť jej zmena, prípadne strata, najmä v spojitosti s tumorom, encefalitídou alebo mozgovej cievnej príhody. Ďalej ju môžeme sledovať v bdelom stave, naopak mizne počas spánku a v stave bezvedomia. Okrem toho sa vyskytuje pri zatvorených očiach a u dospelého jedinca. Charakteristickou vlastnosťou pre alfa aktivitu je jej asymetrickosť (vzostup je strmší v porovnaní so zostupom), nachádzajú sa v skupinách s vretenovitou konfiguráciou. Všeobecne platí tvrdenie, že čím vyššia alfa vlna, tým je aktivita pomalšia s nižšou frekvenciou. Frekvencia alfa rytmu sa pohybuje v rozmedzí 8 – 13,5 Hz (1 Hz predstavuje 1 vlnu za sekundu), amplitúda dosahuje 30 – 100 μV . Synchronizácia v thalamokortikálnych okruhoch sa prejavuje ako pravidelná alfa aktivita, ktorú spozorujeme u zatvorení očí. Ich otvorenie spôsobí desynchronizáciu v thalamokortikálnych okruhoch, čím dôjde k zníženiu amplitúdy vln. Dochádza k blokácii alfa aktivity – ide o reakciu zástavy (RZ/AAR – alpha attenuation reaction) alebo reakciu blokady alfa aktivity (RB), tiež sa používa názov „R“ (responsive), ktorá predstavuje reakciu na otvorenie očí. Po nej sa alfa obnoví buď na krátky čas alebo dlhodobo. Reakciu označujeme ako „P“ (persistent), alfa aktivita pretrváva naďalej aj po podnete. Popisujúci jav nastáva u detí, ktoré trpia poruchou koncentrácie, ako je ľahká mozgová dysfunkcia so syndrómom ADHD alebo psychóz, kde sa sleduje zrýchlenie alfa aktivity o 1 – 2 Hz pri otvorených očiach. Podľa Fullera, z roku 1977 pochádza teória, ktorá poukazuje na menej priaznivé RZ u detí s nižšou inteligenciou. Prieskum bol realizovaný za účasti 10 až 12-ročných chlapcov. Teóriu o rok neskôr upravili Grünnewald-Zuberbier. Štúdium pozostávalo z troch skupín detí rovnakej vekovej kategórii pri rovnakom IQ (110). Výsledky ukázali, že pri zvýšenej koncentrácii dosiahneme lepšie RZ, pričom inteligencia nerozhoduje.

Pokožová synchronizácia rytmov v thalamokortikálnom systéme v stave bdlosti alfa aktivitou sa prejavuje vplyvom ARAS (ascendentného retikulárneho aktivačného systému) na thalamokortikálnu sústavu. Niektoré prípady oligofrenikov vykazujú menší ARAS v komparácii so zdravými jedincami. Zatvorenie očí spôsobí odblokovanie alfy, pri ktorom sa zúčastňujú opäť synchronizačné thalamokortikálne mechanizmy. V tomto stave vlny dosahujú rovnakej fázy s vysokou amplitúdou. Vlny sa opakujú periodicky, naopak, pri otvorených očiach sa vlny vyznačujú nízkou amplitúdou a nepravidlosťou. Niekedy je prítomný tzv. rebound efekt (RE), ktorý sa objaví po zatvorení očí, kedy alfa nadobúda vyššie hodnoty amplitúdy ako pred otvorením očí. Efekt nastáva v stave ospalosti alebo pri stavoch vypätia, môže sa objaviť i u neurotikov.

Beta rytmus prevláda v oblastiach nad frontálnymi lalokmi mozgu. Pôsobí vo frekvenčnom pásme od 14 do 30 Hz s amplitúdou od 2 do 20 μ V. Nereaguje na otvorenie očí. Beta vlny sa vyskytujú u REM spánku. Zvýšenú aktivitu vykazujú ženy a pacienti, ktorí používajú barbituráty. Je ovplyvnená i vekom.

Theta rytmus vykazuje činnosť pri frekvencii 4 až 7,5 Hz. Jeho amplitúda sa pohybuje v rozmedzí 15 až 25 μ V. Jej výskyt pozorujeme najmä v oblasti parietálnej a okcipitálnej u bdelych detí. Theta vlny určíme na EEG zázname počas spánku u dospelých jedincov alebo pri silnej emocionálnej úzkosti. Dvojnásobok hodnoty amplitúdy predstavuje patologický stav.



Obr. 3: Základné frekvenčné hladiny mozgu – EEG rytmy [4]

V neposlednom rade na EEG zázname objavíme aj **delta rytmus** s najnižšou frekvenciou 0,5 až 3,5 Hz o amplitúde 75 až 150 μ V. U dojčiat a počas hlbokého spánku u dospelých ide o fyziologický jav (inak je patologický). Na EEG zázname rozlišujeme ďalej gama, kappa, lambda a mí rytmy.

Použité zdroje: [1], [2], [3], [4]


2 Polysomnografia

EEG vyšetrenie nevyžaduje žiadnu špeciálnu prípravu, vykonáva sa v neurologických ambulanciách. Počas tohto vyšetrenia pacient dostáva inštrukcie od vyšetrujúceho lekára k pokynom, ako sú otvorenie a zatvorenie očí, dýchanie. Snímajú sa elektrické potenciály mozgovej kôry. Celkové vyšetrenie trvá asi 1 až 2 hodiny. Vyšetrenie je možné realizovať i u malých detí.

V prípade polysomnografického vyšetrenia ide o celonočné monitorovacie vyšetrenie, realizované v spánkovom laboratóriu, pričom sa analyzuje EEG, EMG a EOG, ďalej sa sleduje pulzná/transkutánná oxymetria, saturácia krvi kyslíkom, poloha tela počas spánku, pohyby hrudníka a brucha, prípadne EKG.

2.1 Elektromyografia

Generovaný elektromyografický signál vzniká elektrickou činnosťou svalových vlákien. Pri polysomnografickom vyšetrení sa využíva neinvazívnej metódy snímania EMG. Dĺžka trvania EMG signálu je zvyčajne 2 až 15 ms. Jeho amplitúda zodpovedá 20 až 2000 μV pri frekvenčnom rozsahu 20 až 250 Hz. EMG elektródy majú v porovnaní s EEG elektródami menšiu plochu pre vyššiu presnosť snímaného miesta. Meranie svalového tonu prostredníctvom submentálneho EMG (EMGsub) je významné pre rozlíšenie stavu bdlosti od REM fázy spánku. Elektródy sa umiestňujú v oblasti dolnej čeľusti približne 2 cm od krajných bodov. Svalový tonus má tendenciu klesať s hĺbkou spánku v NonREM fáze spánku. Väčšina kostrových svalov je behom REMu atonická.




Obr. 4: Umiestnenie EMG elektród [8]

2.2 Elektrookulografia

Elektrookulogram slúži k zachyteniu pokojových elektrických potenciálov medzi zadným a predným pólom oka, pričom oko slúži ako dipól s kladnou rohovkou a zápornou sietnicou. EOG

signál nadobúda amplitúdy v rádoch stoviek μV až mV . Vzorkovacia frekvencia má obdobné parametre ako u EEG signálu. Využíva sa detekcie rýchlych pohybov očí behom REM fázy spánku. Tie sa zobrazujú v EOG ako vrcholy s veľkosťou do 500 ms. Umiestnenie elektród súvisí s nazálnou a temporálnou oblasťou s využitím referenčnej elektródy na ušnom laloku.


Vzájomným porovnávaním týchto parametrov sme schopní určiť jednotlivé druhy a štádiá spánku, bdelosť. Vyšetrenie sa vykonáva i pre diagnostické účely spánkových a dýchacích porúch. Prístroj určený k polysomnografickému vyšetreniu sa nazýva polygraf (polysomnograf). Polysomnogram je výsledný záznam získaný pomocou polygrafu. Záznam je podávaný v tridsaťsekundových úsekoch, v ktorých sa následne určuje štádium spánku.



Obr. 5: Rozmiestnenie EOG elektród [2]

2.3 Polysomnografická technika


Miestnosť je vybavená dvoma kamerami, ktoré sú nevyhnutné pri sledovaní celého tela pacienta. Pre monitoring sa využíva nízko-svetelnej kamery a infračervenej kamery (zachytenie abnormálnych javov, sledovanie prebúdzania) a ovládač pre manipuláciu s kamerami. V dôsledku nízkej amplitúdy u jednotlivých signálov (μV) sú zosilnené k zobrazeniu a analýze. Filtre sú nevyhnutné k rozpoznaniu a eliminácii zdrojov artefaktov pre lepšiu kvalitu obrazu (biologické artefakty – svalové artefakty, potenie, otvorenie a zatvorenie očí; technické artefakty – elektrostatické potenciály (pri nesprávnom kontakte elektródy s pokožkou), šum elektronických zariadení, sieťová frekvencia 50 Hz, magnetické pole). Napríklad artefakty, ktoré vznikajú pri potení sa vyznačujú vysokou amplitúdou a nízkou frekvenciou (0,2 Hz). Pri nedostatočnej svalovej relaxácii môžu vzniknúť artefakty v oblasti musculus frontalis a temporalis.



Obr. 6: Biologické artefakty pri EEG vyšetrení [1]

Vysoko-frekvenčný filter (low-pass filter) prepúšťa nižšie kmitočty (u EEG kanálov s DP filtrom 70 Hz sa odfiltrujú frekvencie, ktoré sú vyššie ako uvedená hodnota, pričom prepustí nižšie frekvencie). Naopak, použitie nízko-frekvenčného filtra (high-pass filter) umožní priechod vyšším frekvenciám (EEG používa HP filter o frekvencii 0,3 Hz; kmitočty nad 0,3 Hz prepustí, naopak nižšie frekvencie utlmí).

Parametre zosilňovačov sú totožné ako pri klasickom EEG zázname (1 mm = 10 μ V pre zosilnenie, filter 70 Hz, časová konštanta je 0,3 s). V prípade plochého grafu možno zdvojnásobiť zosilnenie (1 mm = 5 μ V). Pri dychových artefaktoch alebo pohybe očí, je časová konštanta vyššia (až 1 s), pri výskyte svalovej aktivity sa používa filter s vyššími frekvenciami (100 až 200 Hz). V tejto kapitole boli využité zdroje: [2], [4], [5], [6], [7], [12]



Obr. 7: Technické artefakty [1]

3 Štruktúra spánku

Spánok je prirodzene nastávajúci a nevyhnutný fyziologický proces, ktorý je dôležitý pre naše zdravie a blahobyt ako pre ľudí, tak aj pre všetky živé organizmy. Spánok môžeme definovať ako periodický stav odpočinku pre myseľ a telo, obvyčajne sprevádzaný zatvorenými očami, čiastočnou alebo úplnou nevedomosťou, relaxáciou a nečinnosťou kostrového svalstva. Za optimálnu hodnotu spánku sa považuje 7 – 8 hodín denne. Hypersomnia predstavuje spánok pri viac ako 10 hodín za 24 hodín. V prípade insomnie (alebo agripnie) ide o spánok kratší ako 5 hodín.

3.1 Spánkové cykly

Spánok tvoria NonREM alebo ortodoxný spánok, ktorý má 4 štádiá synchronného spánku a REM spánok, ktorý nazývame tiež paradoxný spánok. Tieto fázy spánku sa striedajú a cyklicky opakujú v časových intervaloch.

3.1.1 REM spánok

Zvýšenie hladiny hormónu noradrenalínu zapríčini spustenie REM fázy. Charakteristickým znakom REMu je úbytok svalového napätia, mierny pokles telesnej teploty, zmeny v dýchaní (pokles dychovej frekvencie), nepravidelný srdcový rytmus, sťah ciev (tým je srdce vystavené väčšej námahe, čo môže zapríčiniť srdcovú príhodu), erekcia u mužov a prekrvenie v oblasti vagíny u žien. Z názvu vyplýva, že táto fáza sa vyznačuje rýchlymi a nepravidelnými pohybmi očí. Ide o fázu, pri ktorej sa využíva intenzívnej činnosti mozgu v pons Varolii (Varolov most – súčasťou mozgového kmeňa, uložený v zadnej časti mozgu). Paradoxný spánok je spojený s pamäťou, myšlienkovými procesmi a pocitmi regeneračného spánku. Ak je táto fáza spánku nedostatočne umožnená, dochádza k rôznym poruchám s pamäťou a sústredením. Problém sa rieši tzv. rebound efektom, ktorý spôsobuje väčší podiel REM spánku v nasledujúcich nociach. Niektoré úseky REMu pripomínajú bdelý stav.

3.1.2 NonREM spánok

Vznik NonREM podmieňuje vylučovanie hormónu serotonínu v mozgu. Pre NonREM1 (1. štádium NonREM) platí, že človek je schopný najlepšie zaregistrovať a reagovať na vonkajší podnet. Ide o najľahšiu fázu spánku, a preto môže dochádzať k prebudeniu. V tomto štádiu dominujú theta vlny o frekvencii 4 až 7 Hz. Je vyjadrený 5 % celkovej doby spánku. Spánok sa prehĺbuje s príchodom NonREM2, kedy sa začínajú objavovať spánkové vretená, K-komplexy. Prehĺbenie NonREM2 spôsobí, že schopnosť reakcie spiaceho na vonkajší podnet je nižšia. Tvorí približne 50 % spánku. Najhlbší spánok nastáva v 3. a 4. fáze spánku. Nazývame ho tiež pomalý delta spánok. V tomto štádiu spánku je schopnosť prebudenia najnižšia. Podiel delta vln v 3. fáze je 20 až 50 %, pričom v 4. fáze je nepatrne vyššia. 5 až 10 % celkového spánku zaberá 3. fáza NonREM; 10 až 15 % predstavuje 4. fáza synchronného spánku.

Po dvoch hodinách synchronného spánku sa objavuje paradoxný spánok s dobou trvania asi 10 až 20 minút, po ktorom opäťovne nastane fáza povrchného synchronného spánku. Ten sa prehĺbuje s prechodom do 2. a 3. štádia. Cyklus sa opakuje a asi po dvoch hodinách nastáva zase paradoxný spánok. Počas noci sa vystrieda priemerne 4 až 6 týchto cyklov. Priemerná dĺžka trvania cyklu (vystriedanie NonREM a REM fázy) NonREM – REM je 90 minút. Prvá polovica noci zaberá dlhšie cykly, druhá naopak, kratšie. Cykly majú dlhšiu dobu trvania a obsahujú viac synchronného spánku v prvej tretine noci, naopak posledná tretina zaberá cykly s krátkou dobou trvania a viac sa vyskytuje paradoxný spánok. Percentuálne vyjadrenie 1. štádia NonREM zastupuje 5 až 10 %, 2. štádia 50 %, 3. a 4. štádium zaberá 20 až 25 %. 20 až 25 % spánku predstavuje REM fáza. K spontánnemu prebudeniu dochádza v REM spánku. Stupeň spánku ovplyvňuje reaktivitu spiaceho na podnet, ktorá sa prejavuje v hĺbke synchronného spánku tak, že reaktivita na podnet je horšia v prípade, ak je hĺbka štádia spánku väčšia. Okrem reaktivity uplatňuje vplyv aj na prebudenie. U paradoxného spánku zodpovedá 2. štádiu synchronného spánku. U synchronného spánku sa v EEG objavuje aktivita pomalých vln s nízkou amplitúdou, pričom synchronizácia elektrických mozgových potenciálov je vyššia. Naopak paradoxný spánok je vyjadrený rýchlymi vlnami pri nízkej amplitúde. V stave bdlosti (vigility, zaužívaný je tiež pojem štádium 0) môžeme pozorovať v EEG alfa aktivitu, ktorej frekvenčné pásmo je 8 až 13,5 Hz pri zatvorených očiach. Otvorením očí dochádza k jej útlmu a reakcia zástavy je pozitívna (RZ+). Alfa aktivita sa rozpadá a mizne v 1. štádiu NonREM a pozorujeme nepravidelnú theta aktivitu s nízkou až strednou amplitúdou. Objavujú sa tzv. vertexové ostré vlny vyššej amplitúdy v centroparietálnych zvodoch. Sú to bifázické vlny. V 2. štádiu NonREM sa objavuje theta rytmus s vyššou amplitúdou a spánkové vretená (často sa vyskytuje popri vretenách (príp. pred nimi) aj K-komplex – nepravidelné, pomalé, trojfázové delta vlny s vysokou amplitúdou do 100 μ V pri frekvencii 12 až 14 Hz, zoskupených do vretien. Dĺžka trvania K-komplexu je 1 až 4 s). Tieto grafoelementy sa označujú ako modifikované evokované potenciály. Sú dôležité najmä preto, lebo niektoré tvary K-komplexov by sa mohli zameniť a vykazovať mylnú epileptickú aktivitu. V 3. a 4. štádiu NonREM spánku sa vyskytuje častejšia delta aktivita v EEG už po celej ploche lebky (v 3. štádiu sú delta vlny polymorfné s frekvenciou 1 až 3 Hz a amplitúdou 75 μ V s výskytom 25 až 50 % v zvolenej epoche, nad 50 % hovoríme o 4. štádiu synchronného spánku). Menej často sa objavujú aj spánkové vretená spolu s K-komplexmi v 3. štádiu a v 4. štádiu sú vynechané. Jedna epocha predstavuje jednu stranu EEGramu pri dĺžke 30 cm pri posune papiera (krivky na obrazovke) 10 mm za 1 s (pri tomto posune je dĺžka trvania jednej epochy 30 s) a 15 mm za 1 s (jedna epocha je 20 s). Takýmto spôsobom dostaneme percentuálny výpočet časového indexu hľadanej aktivity. Napríklad pri určení delta indexu v NonREM máme 5 cm trvajúcu delta aktivitu – to znamená že 5 cm z 30 cm sa rovná 1/6 (teda 16 %). Tieto percentá zodpovedajú 2. štádiu NonREM spánku.

V paradoxnom spánku je v EEG registrovaná rýchla aktivita pri nízkej amplitúde po povrchu lebky. Zriedka sa vyskytujú frontálne po oboch stranách tzv. pílovité vlny (pravidelné delta vlny s vyššou harmonickou aktivitou). Po REM spánku sa objaví povrchný NonREM (alebo prebudenie). REM spánok sa vyznačuje výskytom snov, ktoré zaberajú až dve tretiny až tri štvrtiny spánku na jednu pätinu až jednu štvrtinu celkového REMu. Prieskum v roku 1966 (Hall Calvin, Van de Castle) potvrdil, že 64 % snov je spojených s negatívnymi pojmami (smútok, hnev a strach), pričom asi len 18 % snov je príjemných a veselých. Prieskum bol pozorovaný na 10 000 snoch zdravých ľudí. Predpokladom pre vytváranie negatívnych situácií v sne súvisí s inštinktom sebazáchovy. Sny sa môžu vyskytovať i vo fáze NonREM spánku, pričom ide o sny fádne, pripomínajúce útržky logického myslenia. Použité zdroje pre túto kapitolu: [2], [5], [6], [7], [8], [10], [11], [19]

4 Hypnogram

Súhrnný popis získaných výsledkov z polysomnogramu počas spánku sa nazýva hypnogram, charakterizovaný grafickým zobrazením druhov a štádií spánku v závislosti na čase, v podobe histogramu (stĺpcového diagramu). Hypnogram demonštruje rozdiely v spánku v populácii a uľahčuje rozpoznanie spánkových porúch.

Hypnogram nesie informácie o toku spánkových fáz počas noci, oximetrii, výskyte respiračných príhod. Tieto informácie popisuje horizontálny smer hypnogramu. Vertikálna rovina sleduje vplyv polohy tela a fázy spánku v závislosti na dýchaní a okysličení.

Hypnogramy sú zobrazené zvyčajne v 8 – hodinových záznamoch. Na vertikálnej osi (x) leží časový interval, zatiaľ čo horizontálna os (y) zobrazuje jednotlivé spánkové štádiá. Fáza prebudenia sa označuje číslom 0 a zastupuje najvyššiu časť na osi. Pod ňou sa nachádza REM fáza. Najnižšiu časť v grafe zaberá NonREM fáza (najskôr N1, potom štádiá N2 a N3). V EEG zázname vykazuje REM najvyššej podobnosti s fázou Waking. Medzi W a N1 dosahuje vyšších hodnôt. Fáza W zaberá viac ako 50 % alfa vln, pričom dosahuje svojho maxima v okcipitálnej oblasti mozgu počas zatvorených očí. Po otvorení očí dochádza k jej útlmu. Centrálna oblasť EEG poskytuje informácie o N1 spánku s výskytom vertexových theta vln. N2 sa prejavuje prítomnosťou K-komplexov (frontálne EEG) alebo spánkových vretien (centrálne EEG). Prítomnosť pomalých, delta vln charakterizuje N3 stav. Typickým rysom pre REM sú impulzy rýchlych pohybov očí u EOG a veľmi nízka amplitúda EMG, pílovité vlny na centrálnom EEG, zamieňa sa s N1. Hypnogramy u detí a ľudí nižšieho veku poukazujú na dlhší hlbší spánok, u starších ľudí je spánok naopak ľahší.

Podľa pravidiel R&K (1968) pre klasifikáciu spánkových stavov je NonREM bližšie špecifikovaný ako S1, S2, S3 a S4 štádium. Klasifikácia podľa AASM (2007) publikuje rozdelenie NonREM do N1, N2 a N3 skupín, pričom N3 obsahuje N3 a N4 stavy. Obe príručky tiež klasifikujú bdelosť – Wake (W), REM spánok a Movement time (MT). Podľa oboch manuálov je záznam segmentovaný na 30s epochy.

4.1 Klasifikácia hypnogramu

4.1.1 Jednvrstvé a mnohvrstvé umelé neurónové siete

Nevýhodou jednvrstvových UNS je obmedzenosť v rámci učenia len lineárnymi rozdeľovačmi, ako sú priamky, roviny, nad roviny. (ide o hranice, ktoré oddeľujú určité triedy vo vstupnom priestore).

Naopak, výhodou mnohvrstvových UNS je schopnosť reprezentovať nelineárne funkcie. Typickým príkladom sú sigmoidálne UNS trénované spätným šírením chýb, tzv. backpropagation. Zápornou vlastnosťou je náročnosť učenia.

4.1.2 Rozhodovací strom

Metóda rozhodovacieho stromu je účinným štatistickým prostriedkom pre klasifikáciu, predikáciu, interpretáciu a manipuláciu s dátami. V štruktúre klasifikačných stromov sú nositeľom jednotlivých tried listy, zatiaľčo uzly popisujú testy hodnôt jednotlivých príznakov. Z uzlov vychádza konečný počet vetiev, teda počet rôznych hodnôt, ktoré nadobúda test (zvyčajne binárne). Konečná premenná nesúca spojené hodnoty (zvyčajne reálne hodnoty), sa nazýva regresný strom.

Jej aplikácia má potenciálny význam v oblasti medicíny. Použitie modelu poskytuje radu pozitívnych vlastností, ako sú zjednodušenie komplexných vzťahov medzi vstupom a výstupom rozdelením pôvodných vstupných veličín do významných podskupín, nenáročnosť učenia a interpretácie, neparametrický prístup bez distribučných predpokladov.

Na druhej strane, potencionálnym problémom tejto metódy je možnosť overfittingu a underfittingu najmä pri aplikácii malých dát, čím môže obmedziť robustnosť výsledkov.

Pre určenie stromového učenia slúžia 3 ukazovatele: resubstinenčný odhad (1), odhad testovanej vzorky (2) a v-fold cross-validácia (3).

$$R(d) = \frac{1}{N} \sum_{i=1}^N X(d(x_n) \neq j_n) \quad (1)$$

$$R(d) = \frac{1}{N_2} \sum_{(x_n, j_n) \in Z_2} X(d(x_n) \neq j_n) \quad (2)$$

$$R(d^{(v)}) = \frac{1}{N_v} \sum_{(x_n, j_n) \in Z_v} X(d^{(v)}(x_n) \neq j_n) \quad (3)$$

kde: X funkčný ukazovateľ
X = 1 ak je tvrdenie $X(d(x_n) \neq j_n)$ pravdivé
X = 0 ak je tvrdenie $X(d(x_n) \neq j_n)$ nepravdivé
d(x) klasifikátor
Z₂ vzorka zo základného dáta setu
d^(v)(x) vypočítaný zo vzorky Z – Z_v

4.1.3 kNN klasifikátor

K-NN klasifikáciu zaraďujeme medzi neparametrické metódy klasifikácie. Ide o jednoduchý algoritmus ukladania všetkých dostupných prípadov a klasifikácie nových prípadov na základe podobnosti (funkcie vzdialenosti). Už v počiatku 70-ich rokov sa využívala klasifikácia kNN pre štatistický odhad a rozpoznanie znakov.

Klasifikácia prebieha prostredníctvom najbližších bodov tak, že prípad prislúcha triede, ktorá je najbližšie k susediacim bodom, vypočítané pomocou vzdialenostnej funkcie. V prípade, že k = 1, prípad priradí triede najbližšieho suseda. Pre výpočet funkcie vzdialenosti slúžia Euklidovský výpočet vzdialenosti (4), Manhattanský výpočet (5) a Minkowský výpočet pre vzdialenosť (6).

$$\sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (4)$$

$$\sum_{i=1}^k |x_i - y_i| \quad (5)$$

$$(\sum_{i=1}^k (|x_i - y_i|)^q)^{1/q} \quad (6)$$

Platnosť týchto výpočtov je obmedzená pre spojité premenné, v prípade kategorickej premennej musí byť uplatnená Hammingova vzdialenosť (7).

$$D_H = \sum_{i=1}^k |x_i - y_i| \quad (7)$$

$$x = y \Rightarrow D = 0$$


$$x \neq y \Rightarrow D = 1$$

Pre správnosť klasifikácie je dôležitý výber optimálnej k hodnoty. Vyššia hodnota poskytuje lepšie výsledky triedenia, no zároveň nemusí zaručiť maximálnu presnosť klasifikátoru. Vzájomná validita umožňuje určenie k hodnoty pri použití nezávislého súboru dát, pričom najpriaznivejšie výsledky vykazujú k rovné 3-10.

Istou nevýhodou tejto klasifikácie je nejasnosť tvaru pravdepodobnostných charakteristík tried, ďalej pomalé rozhodovanie, vysoká pamäťová náročnosť (možnosťou kondenzácie trénovanej množiny), neschopnosť generalizácie, chyba Bayesovského klasifikátora.

Na druhej strane má klasifikátor radu výhod, medzi ktoré patrí jednoduchý návrh a implementácia. Okrem iného chyby metód k-NN a UNS sú porovnateľné. K predstavuje veľkosť trénovanej množiny. Zvyčajne sa používa klasifikácia podľa jedného suseda, teda 1-NN. [13], [16], [17]

4.1.4 SVM klasifikátor



Obr. 8: Princíp SVM [9]

Ide o podporné vektory, ktoré vytvárajú určitú skupinu jadrových algoritmov (kernel machines) z oblasti strojového učenia. Reprezentujú jednak lineárne funkcie, ako aj nelineárne.

Postupuje sa tak, že pôvodný vstupný priestor sa prevedie do viacdimenzionálneho, čo umožní oddelenie jednotlivých tried lineárne. SVM umožňuje klasifikáciu pomocou nad roviny tak, že maximalizuje oblasť (margo), vymedzujúcu dve triedy. Vektory, ktoré definujú túto nad rovinu, sa nazývajú podporné vektory.

Binárna klasifikácia podľa SVM


Obvykle sa využíva klasifikácia do dvoch kategórií – binárna klasifikácia. Pre lineárne separovateľné dáta klasifikátor nájde vhodnú lineárnu hranicu. Spomedzi všetkých sa vyberie tá, ktorá zabezpečí najširšiu oddeľovaciu líniu medzi oboma triedami. Krajné body oboch tried potom určujú optimálny smer a polohu oddeľujúcej roviny (podporné vektory). Algoritmus poskytuje kernel transformáciu, ktorá umožňuje prevod pôvodne nonseparovateľnej úlohy do separovateľnej (priestor vyššej dimenzie). Na túto transformáciu je aplikovaný optimalizačný algoritmus, ktorý rieši rozdeľovaciu rovinu. Jej výpočet závisí na skalárnom súčine (transformovaných dát $\langle f(x), f(x_1) \rangle$) $K(x, x_1)$. Kladnou vlastnosťou tejto transformácie je aplikácia pre rôzne typy objektov (grafy, stormy,...).

Lineárna klasifikácia nevyžaduje žiadnu kernel transformáciu. V prípade separovateľných dát platí, že nad rovinu rozdeľujúcu body do dvoch tried definuje rovnica (8):

$$w \cdot x + b = 0 \quad (8)$$

kde:	w	normála nad roviny
	$\ w\ $	Eukleidovská norma
	$ b / \ w\ $	vzdialenosť nad roviny a počiatku súradníc
	d_+, d_-	najkratšia vzdialenosť najbližších bodov oboch strán nadroviny definovaná ako maximálna šírka hraničného pásma

Podporné vektory potom ležia na hranici tohto pásma.



Obr. 9: Hľadanie optimálnej separovateľnej roviny. Body na okrajoch pásma sú hľadané podporné vektory [10]

V prípade, že pre všetky body platí:

$$\begin{aligned}\vec{x}_i \cdot \vec{w} + b &\geq +1 & \text{pre } y_i = +1 \\ \vec{x}_i \cdot \vec{w} + b &\leq -1 & \text{pre } y_i = -1\end{aligned}\quad (9)$$

Klasifikácia vstupného vektora x prebieha na základe dvojice vektorov (vektor váh w a vektor prahu b).


$$\text{sgn}(\mathbf{w} \cdot \mathbf{x} + b) \quad (10)$$

Pre krajné body platí nasledujúce:

$$\begin{aligned}\mathbf{w} \cdot \mathbf{x}^+ + b &= 1 \\ \mathbf{w} \cdot \mathbf{x}^- + b &= -1\end{aligned}\quad (11)$$

Šírka hranice oboch tried je:

$$\begin{aligned}M &= (\mathbf{x}^+ - \mathbf{x}^-) \cdot \mathbf{n} \\ M &= (\mathbf{x}^+ - \mathbf{x}^-) \cdot \frac{\mathbf{w}}{\|\mathbf{w}\|} = \frac{2}{\|\mathbf{w}\|} \\ \max \frac{2}{\|\mathbf{w}\|} &\end{aligned}\quad \begin{aligned} &\max \frac{2}{\|\mathbf{w}\|} \\ &s.t. \\ &(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1, \quad \forall \mathbf{x}_i \text{ z triedy 1} \\ &(\mathbf{w} \cdot \mathbf{x}_i + b) \leq -1, \quad \forall \mathbf{x}_i \text{ z triedy 2} \end{aligned}\quad (12)$$



Obr. 10: Matematická formulácia SVM [10]

V prípade, že jednotlivé triedy klasifikujeme hodnotami 1 a -1:

$$\begin{aligned} (\mathbf{w} \cdot \mathbf{x}_i + b) &\geq 1, \quad \forall \mathbf{x}_i \text{ z triedy 1, t.j. } y_i = 1 \\ (\mathbf{w} \cdot \mathbf{x}_i + b) &\leq -1, \quad \forall \mathbf{x}_i \text{ z triedy 2, t.j. } y_i = -1 \end{aligned} \quad (13)$$

Nasledujúce podmienky budú mať tvar:

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1, \quad \forall \mathbf{x}_i \quad (14)$$

A teda výsledný optimalizačný tvar bude dvojaký:

$$\begin{aligned} \max \frac{2}{\|\mathbf{w}\|} \quad \text{alebo} \quad \min \frac{1}{2} \|\mathbf{w}\|^2 \\ \text{s.t. } y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1, \quad \forall \mathbf{x}_i \end{aligned} \quad (15)$$

Tab. 2: Porovnanie jednotlivých klasifikátorov

Klasifikátor	UNS	Rozhodovací strom	kNN	SVM
+	Schopnosť učenia lineárnych i nelineárnych funkcií	nenáročnosť učenia, neparametrický prístup	jednoduchý návrh a implementácia	klasifikácia lineárnych, nelineárnych funkcií, kernel transformácia, regresná analýza
-	náročnosť učenia	overfitting, underfitting pri malých dátach	vysoká pamäťová náročnosť, pomalé rozhodovanie	pamäťové nároky, znížená rýchlosť algoritmu pri obsiahlych úlohách, vhodná kernel funkcia

Použité zdroje pre túto kapitolu : [13], [16], [19]

5 Hodnotenie kvality spánku

Pri hodnotení spánku sa hodnotia rôzne faktory, ako je dĺžka spánku a jeho distribúcia počas 24 hodín, veľmi dôležitým aspektom je kvalita spánku. Metódy pre hodnotenie spánku zohľadňujú viacero hľadísk (trvanie, kvalita, spánková architektúra a harmonogram).

Kvantitatívne hodnotenie spánku zahŕňa jeho trvanie, denný spánok, nočný spánok, reálny čas spánku (bez prítomnosti W počas spánkového cyklu). Kvalitatívne hodnotenie spánku sleduje výskyt prebudení počas spánkového cyklu, jeho efektivitu, spánkové poruchy (spojené s dýchaním, napr. chrápanie), parasomnie počas spánku. Hodnotiace metódy spánkovej architektúry pozostávajú zo sledovania rozloženia spánkového NonREM, REMU a spektrálnej distribúcie EEG záznamu počas spánku. U spánkového harmonogramu sa hodnotí započatie spánku (čas), čas ranného prebudení, rozloženie zdriemnutí počas dňa, periodické odhady spánku počas 24 hodín. Tieto hodnotiace faktory sú vzájomne prepojené.

U zdravých jedincov dochádza k rôznorodosti hypnogramov v závislosti na veku, emocionálnom vypätí a faktoroch okolitého prostredia. Optimálna dĺžka spánku u zdravého, dospelého jedinca sa pohybuje v rozmedzí 7 – 9 hodín za noc (priemerne 8 hodín). 20 – 25 % celkovej doby spánku zaberá REM spánok u dospelého, zdravého jedinca. Tento pomer sa proporčne mení s vekom (u novorodencov dosahuje 50 % až 80 % celkovej doby spánku). Dĺžka jedného cyklu REMU u dospelého jedinca predstavuje v priemere 90 – 120 minút. REM fáza dominuje v neskoršej perióde spánku, obzvlášť pred prebudením. Tzv. mikroprebudení nastanú po REM spánku a zvyčajne je dĺžka týchto prebudení niekoľko sekúnd, pričom spiaci jedinec si ich po prebudení nepamätá. Tieto mikroprebudení sa môžu počas spánkového cyklu negatívne prejavovať na kvalite spánku spiaceho, pričom môžu znamenať určitú spánkovú poruchu. Rozdeľujú sa podľa dĺžky trvania na ultrakrátke prebudení v rozmedzí niekoľko sekúnd, krátke spontánne prebudení s dĺžkou trvania niekoľko minút a dlhodobé prebudení. Dôležitým faktorom, ktorý ovplyvňuje výskyt mikroprebudení je vek. Elektrofyziologické kritériá uvádzajú mieru prebudení počas spánku menej ako 5 % z celkovej doby spánku (u dospelých jedincov). 5 % až 10 % celkového spánku zaberá N1, podiel N2 fázy dosahuje 45 – 50 % celkového spánku (najviac spánku), N3 a N4 spánok zaberá 50 %. Viac delta spánku sa vyskytuje u detí a mladých ľudí. U dospelých tento podiel klesá a u starých ľudí sa vyskytuje v minimálnej miere alebo vôbec.


REM a NonREM sa cyklicky striedajú počas noci v 4 alebo 5 cykloch (niekedy aj menej). Prvý spánkový cyklus dosahuje dĺžky približne 90 minút (priemerne 70 – 100 minút, u detí menej). Každý cyklus začína štádiom N1, prechádza cez N2 a N3 (N3 a N4) a po perióde delta spánku opäť prechádza cez N3, N2 a N1. V štádiu N1 nenastane prebudenie, naopak ho vystrieda krátka perióda REMU, po ktorom nasleduje nový cyklus. U neskoršej periódy spánku dochádza k úbytku trvania SWS, a narastaniu dĺžky trvania REMU (najmä u posledných dvoch cyklov je distribúcia REMU väčšia).

Použité zdroje: [18], [19], [20]

6 SOFTWARE

6.1 MATLAB

Matlab je programovacie prostredie s vlastným programovacím jazykom, ktorý umožňuje vedecko – technické výpočty, modelovanie, návrhy algoritmov počítačových simulácií, analýzu merania a spracovania signálov, návrhy riadiacich a komunikačných systémov. Súčasťou matlabu je Simulink, Toolbox, Guide. Hlavným vývojovým lídrom tohto matematického výpočtového softvéru je spoločnosť Mathworks. Grafické rozhranie matlabu tvorí príkazové okno Command window, okno zobrazujúce aktuálnu zložku Current folder, pracovná oblasť Workspace, a okno pre históriu príkazov Command history. Matlab ukladá premenné do *.mat súboru.



Obr. 11: Prostredie matlab

6.1.1 VSTUPNÉ DÁTA

V tejto práci bol uplatnený jazyk matlab najmä pre jednoduchosť spracovania biologických signálov.

K dispozícii bola voľne dostupná online databáza *THE SLEEP – EDF DATABASE*, s výberom 8 polysomnografických záznamov pre prácu s algoritmom.

Spánková databáza obsahuje 61 polysomnogramov a hypnogramov. *PSG.edf súbory tvorí komplex 7 záznamov (EEG záznamy (pre snímanie mozgovej aktivity boli použité zvody Fpz – Cz a Pz – Oz), EOG záznamy, submentálne EMG, telesná teplota, respiračné signály a event markery). *Hypnogram.edf súbory sú popísané ako W, R, 1, 2, 3, 4, M a ?, pričom ide o stav bdlosti, REM, NonREM1 – 4, pohybová aktivita v súvislosti so spánkom a náhodný signál. Jednotlivé štádiá sú

kódované v dvojkovej sústave ako 0, 1, 2, 3, 4, 5, 6 a 9. Vznik hypnogramov bol podmienený príručkou podľa Rechtschaffen a Kalesa (1968). Namiesto zvodov C4 – A1, C3 – A2 boli použité Fpz – Cz a Pz – Oz. Polysomnografické záznamy a hypnogramy sú naformátované v .edf. Formát je členený do HEADER, v ktorom je obsiahnutý súhrnný popis pacienta a RECORD, ktorý poskytuje namerané dáta jednotlivých biologických signálov. Sc* záznamy boli získané v roku 1989 na pacientoch bez akýchkoľvek spánkových porúch počas 24 hodín. St* spánkové záznamy pochádzajú z roku 1994, pacienti boli zdraví (mierne problémy pri spontánnom zaspávaní). Záznamy boli namerané s použitím telemetrického systému.

Dobrovoľníci sú kaukazského pôvodu, vo veku 21 až 33 rokov. Pre tréning algoritmu boli použité záznamy SC4002E0 a SC4102E0.

Tab. 3: Databáza použitých záznamov pre tvorbu spánkového diagramu

Záznam	Pohlavie	Vek
SC4002E0	žena	33
SC4012E0	žena	33
SC4102E0	muž	25
SC4112E0	muž	26
ST7022J0	žena	25
ST7052J0	žena	31
ST7121J0	muž	21
ST7132J0	muž	23

Použité zdroje: [14], [15], [17]

6.1.2 VERIFIKÁCIA DÁT

Pracovalo sa najmä s polysomnografickými signálmi EEG Fpz – Cz, EEG Pz – Oz, EOG a EMG. Po prevedení verifikácie vstupných dát (pre konzistentnosť dát) poskytl úplný hypnogram, pozostávajúci z 8 spánkových stavov len dva záznamy (SC4002E0 a ST7121J0).

```
Command Window

File sc4002e0.hyp has these unique classes:
    0    1    2    3    4    5    6    9

File sc4002e0.hyp passed the complexity test.

File sc4012e0.hyp has these unique classes:
    0    1    2    3    4    5    9

File sc4012e0.hyp has failed the complexity test.

File sc4102e0.hyp has these unique classes:
    0    1    2    3    5    6    9

File sc4102e0.hyp has failed the complexity test.

File sc4112e0.hyp has these unique classes:
    0    1    2    3    4    5    9

File sc4112e0.hyp has failed the complexity test.

File st7022j0.hyp has these unique classes:
    0    1    2    3    4    5    9

File st7022j0.hyp has failed the complexity test.
```

Obr. 12 Test komplexity – výpis do Command Window

```
Command Window

File st7052j0.hyp has these unique classes:
    0    1    2    3    4    5    9

File st7052j0.hyp has failed the complexity test.

File st7121j0.hyp has these unique classes:
    0    1    2    3    4    5    6    9

File st7121j0.hyp passed the complexity test.

File st7132j0.hyp has these unique classes:
    0    1    2    3    4    5    9

File st7132j0.hyp has failed the complexity test.
```

Obr. 13 Test komplexity – výpis do Command Window

Vzorkovacia frekvencia signálov bola definovaná 100 Hz na 1 vzorku signálu v prípade EEG a EOG signálov; pre EMG signál bola vzorkovacia frekvencia 1 Hz, u záznamov ST bol EMG signál navzorkovaný 100 Hz / s. Dĺžka epochy EEG signálu predstavuje 30 s.

Tab. 4: Overenie dĺžky záznamu

Dáta	Hlavička (rec súbor)	Dĺžka dát (rec súbor)	Hlavička (hyp súbor)	Dĺžka dát (hyp súbor)	Vypočítaná dĺžka záznamu (hlavička hyp súboru)	Odhadovaná dĺžka záznamu v hypnogramе (rec súbor)
SC4002E0	1415	8490000	2831	2831	2998.940304	3000
SC4012E0	1425	8550000	2851	2851	2998.947738	3000
SC4102E0	1429	8574000	2859	2859	2998.950682	3000
SC4112E0	1390	8340000	2781	2781	2998.921251	3000
ST7022J0	3979	3979000	1327	1327	2998.492841	3000
ST7052J0	3871	3871000	1291	1291	2998.450813	3000
ST7121J0	3729	3729000	1244	1244	2997.588424	3000
ST7132J0	3472	3472000	1158	1158	2998.272884	3000

6.1.1 EXTRAKCIA PRÍZNAKOV

6.1.1.1 SEGMENTÁCIA

Výpočet PSD

Výkonová spektrálna hustota predstavuje grafické zobrazenie frekvenčného pásma. Je definovaná ako plocha pod krivkou, ktorá sa vyjadruje v absolútnej hodnote jednotlivých komponentov. Výkonové spektrum udáva rozloženie výkonu signálu v závislosti na frekvenčných zložkách.

$$S_p(\omega) = \frac{2}{\pi} \int_0^{\infty} R_p(\tau) \cos \omega \tau d\tau \quad (16)$$

kde: $S_p(\omega)$ výkonová spektrálna hustota


Welchova metóda slúži k odhadu rozloženia výkonu signálu v závislosti na rôznych frekvenčných spektrách. Metóda sa zakladá na koncepte použitia odhadu spektra periodogramu pri konvertovaní signálu z časovej domény do frekvenčnej. Jednou z hlavných výhod tejto metódy je možnosť redukovania šumu v odhadovanom spektre v porovnaní s klasickým periodogramom alebo Bartlettovej metódy. Pri svojom výpočte využíva Bartlettovho princípu rozdelenia signálu do segmentov s definovaným prekrytím a následne aplikovaním oknovej funkcie na jednotlivé segmenty. Pre výpočet využíva diskretnú Fourierovu transformáciu. Výpočet závisí na druhej mocnici jednotlivých zložiek frekvenčného spektra.

Pri extrahovaní vzoriek pre klasifikátor bola využitá frekvenčná doména EEG, EOG a EMG signálov. Frekvenčné spektrum signálov bolo vypočítané na základe odhadu Welchovej metódy s využitím hammingovej oknovej funkcie s dĺžkou signálov EEG, EOG a EMG s prekrytím okna 50 %. Pre lepšie klasifikovanie spánkových stavov bola určená dĺžka posuvu okna N na hodnotu 2500, ktorá bola následne použitá pri výpočte výkonovej spektrálnej hustoty.

```
[psd_EEG_FpzCz,freq_EEG_FpzCz] =  
pwelch(EEG_FpzCz(i:i+N),hamming(N),[],NFFT,Fs);
```


Obr. 14: Výpočet PSD v matlabe

Pre klasifikáciu bol použitý výpočet PSD na konkrétnych frekvenčných pásmach. Najskôr boli vypočítané frekvenčné spektrá základných rytmov pre oba kanály EEG (delta pásmo na frekvenciách 0, 5 – 3, 5 Hz, theta pásmo na frekvenciách 4 – 7, 5 Hz, alfa pásmo na frekvenciách 8 – 13, 5 Hz a beta pásmo pre frekvencie 14 – 30 Hz). Pre nedostatočné výsledky boli využité ďalšie frekvenčné pásma. Ďalším rozlišovacím znakom boli kalkulácie PSD na frekvenciách 11 –16 Hz (prítomnosť spánkových vretien v EEG zázname). Výpočty boli prevedené opäť na oboch kanáloch EEG signálu. Pre lepšie rozlíšenie spánku a vigility boli do klasifikátoru zaradené vzorky REM (PSD delty), NonREM (PSD thety a PSD spánkových vretien) a Wakefulness (PSD bety a PSD alfy) pre EEG_FpzCz a EEG_PzOz.



Obr. 15 Výkonová spektrálna hustota pre EEG signál (kanál Fpz – Cz) pre SC4002E0

Ďalším spracovaným signálom pre klasifikáciu bol EOG signál. Využité boli najmä odlišovacie frekvenčné pásma 1 – 2 Hz, 2 – 4 Hz, 4 – 8 Hz a 8 – 16 Hz (zostupná, pravá, vzostupná a ľavá časť). Pre EMG signál bol prevedený výpočet PSD po celom spektre.

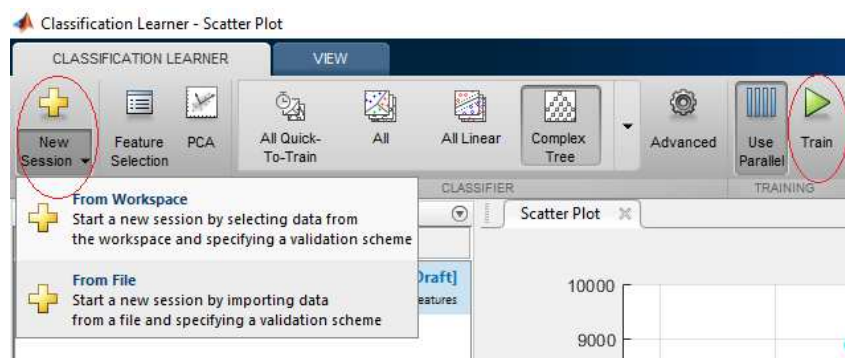


Obr. 16 Výkonová spektrálna hustota pre EEG signál (kanál Pz – Oz) pre SC4002E0

6.1.2 KLASIFIKÁCIA

LEARNING TOOLBOX

Pri zhotovovaní hypnogramu boli využité viaceré dostupné klasifikátory. Celý proces učenia bol prevedený v LEARNING TOOLBOX v matlabe. Celá klasifikácia pozostáva z fázy tréningu a testovacej fázy. V ponuke možností v hornom paneli zakliknutím New Session navolíme možnosť importu dát (pracovná plocha matlabu alebo *.mat súbor). Po výbere feature vektoru a vhodného klasifikátoru (opäť v hornom paneli možností kolonka Train) spustíme tréning nami navolenej klasifikácie.



Obr. 17: Započatie novej klasifikácie – import feature vektoru

6.1.2.1 TRÉNOVANIE KLASIFIKÁCIE

```
Tr1 = [Tr1; psd_delta_EEG_FpzCz' psd_theta_EEG_FpzCz' psd_alfa_EEG_FpzCz'  
      psd_beta_EEG_FpzCz' psd_spindles_EEG_FpzCz'];
```

Obr. 18: Trénovací vektor

The screenshot shows the MATLAB Learning Toolbox interface with three steps:

- Step 1: Select a table or matrix.** A list of variables is shown, including 'prediction_data', 'Awake_new', 'Awake_orig', 'EEG_FpzCz', 'EEG_PzOz', 'EMG', 'EOG', 'Fs', 'FaeEMG', 'HYP', 'L', 'L_hyp', 'M', 'N', 'N1_new', 'N1_orig', 'N2_new', 'N2_orig', 'N3_new', 'N3_orig', 'N4_new', 'N4_orig', 'NFFT', 'PP', 'PSG', 'REM', 'REM_new', 'REM_orig', 'RR', 'R_new', 'R_orig', and 'TEST_DATA_COMPLEX_TREFF'. The 'prediction_data' variable is selected.
- Step 2: Select predictors and response.** A table lists predictors and their ranges. The 'hypnogram' variable is selected as the response.
- Step 3: Define validation method.** The 'Holdout Validation' method is selected, with a 'Percent held out' of 50%.

At the bottom, a red message states: 'Response variable is numeric. Distinct values will be interpreted as class labels.'

Obr. 19: Extrakcia feature vektoru v LEARNING TOOLBOX

Vstupný feature vektor predstavuje predication_data1 – predication_data5148 pre zvolenú klasifikáciu (predication_data). Súčasťou tabuľky je hypnogram, podľa ktorého budú predikačné dáta zaradené do jednotlivých tried (spánkových stavov) hypnogramu.

```
prediction_data = [Tr1 Tr2 Tr3 Tr4 Tr5 Tr6];
```

Obr. 20: Feature vektor v matlabe

Pri možnostiach výberu validačnej metódy bola použitá 50% metóda zádrže (využíva sa pri veľkých dátach, aby nedošlo k preučeniu modelu, čím by došlo k skresleniu výsledkov), ktorá ovplyvnila rýchlosť trénovania predikačného modelu.

Step 3
Define validation method.

☐ **Cross-Validation**
Protects against overfitting by partitioning the data set into folds and estimating accuracy on each fold.

Cross-validation folds: 5 folds

☐ **Holdout Validation**
Recommended for large data sets.

Percent held out: 50%

☐ **No Validation**
No protection against overfitting.

[Read about validation](#)

Obr. 21: Navolenie validačnej metódy


Vstup klasifikátoru si vyžadoval formát tabuľky, preto bolo potrebné dáta konvertovať pomocou príkazu, keďže naše dáta boli spracované ako matica o veľkosti 2831 x 5149 prvkov. Veľkosť predikačného dáta setu bola 112 MB.

```
prediction_data = array2table(prediction_data);
```


Obr. 22: Prevedenie dát do tabuľkového formátu

LINEÁRNA SVM KLASIFIKÁCIA

Prvý trénovaný klasifikátor bol lineárny SVM. Po jeho trénovaní sme dostali výsledný predikačný model s presnosťou zostavenia 90, 6 %. Trénovaný algoritmus spotreboval pre svoju činnosť najdlhší čas. Výsledky zahŕňajú taktiež kvadratickú a kubickú SVM klasifikáciu.




Obr. 23: Rozloženie dát (jednotlivé triedy 0 – 9 sú farebne odlíšené podľa čestnosti výskytu)




Obr. 24: SVM model 1 (na obrázku sú krížikom označené nesprávne klasifikované body)

Confusion matrix plot je grafické vyjadrenie trénovaného klasifikátora, ktoré udáva počet pozorovaní jednotlivých tried v každej bunke. Riadky grafu vyjadrujú skutočnú triedu, zatiaľ čo stĺpce zodpovedajú predikčnej triede. Diagonála predstavuje spojenie predikčnej a skutočnej triedy. V prípade správnej klasifikácie je označená zelenou farbou. Confusion matrix udáva skutočnosť, v akej miere sa ujal daný klasifikátor v konkrétnych oblastiach. Vyjadrenie v % udáva zobrazenie skutočne pozitívneho a falošne negatívneho pomeru.




Obr. 25: SVM model 1 – Confusion matrix, zobrazujúca počet pozorovaní klasifikovaných tried



Obr. 26: Confusion matrix – zobrazenie skutočne pozitívneho a falošne negatívneho pomeru lineárnej SVM klasifikácie

Prvý graf udáva závislosť počtu pozorovaní klasifikovaných tried (do akej miery sa uplatnil daný klasifikátor pri klasifikácii jednotlivých tried). Druhý graf zobrazuje závislosť skutočne pozitívneho a falošne negatívneho pomeru predikačných a skutočných tried. Túto závislosť vyjadruje v %. Vedľa grafu sa nachádzajú dva stĺpce – skutočne pozitívny a falošne negatívny pomer. Trieda 0 bola klasifikovaná so správnosťou 98 %. Zvyšné 2 % predstavujú falošne negatívny pomer pre nesprávne klasifikované body triedy 0. Skutočne pozitívny pomer pre triedy 2, 4 a 5 dosiahol približne 90 %. Falošne negatívny pomer s neúspešnom klasifikáciou (100 %) sa prejavil u tried 1, 6 a 9.

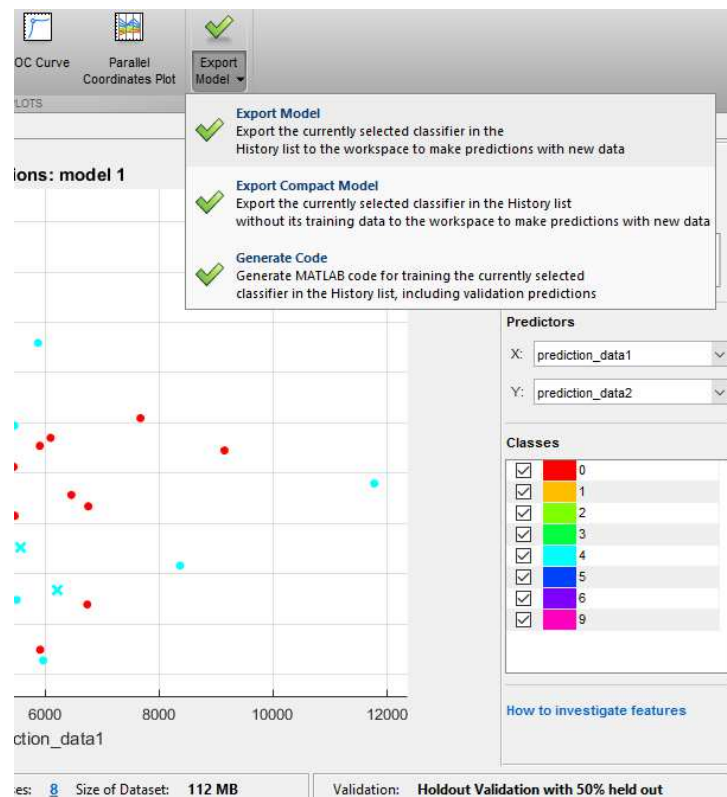
ROC krivka zobrazuje skutočne a falošne pozitívny pomer aktuálne zvoleného tréňovaného klasifikátoru, kde je možné vykreslenie pre jednotlivé klasifikované triedy. Ukazovateľ na grafe prezentuje prevedenie účinnosti daného klasifikátoru (hodnoty skutočne pozitívneho pomeru (TPR) a falošne pozitívneho pomeru (FPR)).



Obr. 27: ROC krivka pre lineárny SVM klasifikátor (s porovnávacou – pozitívnu triedou 0)


Na obrázku je zakreslený graf ROC krivky, kde hodnota AUC bola 1 (veľká plocha pod krivkou predstavuje správnu klasifikáciu). Správnosť danej klasifikácie bola overená pravouhlým tvarom krivky. Hodnota skutočne pozitívneho pomeru bola 0, 98, a teda správnosť klasifikovanej triedy 0 bola 98 %. 2 % lineárnej SVM podliehali nesprávne klasifikovanej vigilite (hodnota falošne pozitívneho pomeru – 0, 02).

Po tréovaní bol SVM model exportovaný do Workspace v matlabe ako Linear_Svm.mat, s ktorým sa následne pracovalo pri testovaní na dátach.




Obr. 28: Export tréovaného modelu

KVADRATICKÁ SVM KLASIFIKÁCIA




Obr. 29: SVM model 2 (na obrázku je možné vidieť nesprávne klasifikované body označené krížikom)

Kvadratická klasifikácia poskytla predikačný model zostavený na 89, 9 %. Výsledný model tréningu bol exportovaný do Workspace ako Quadratic_Svm.mat.




Obr. 30: SVM model 2 – Confusion matrix, zobrazujúca počet pozorovaní klasifikovaných spánkových úrovní



Obr. 31: Confusion matrix – zobrazenie skutočne pozitívneho a falošne negatívneho pomeru kvadratickej SVM klasifikácie

Grafy Confusion matrix (prvý graf vyjadruje počet pozorovaní účinnosti klasifikácie tried, druhý graf zobrazuje túto účinnosť v %) u lineárnej a kvadratickej SVM klasifikácie poskytli obdobné výsledky klasifikovania spánkových úrovní. Avšak v porovnaní s lineárnym SVM klasifikátorom bola táto metóda úspešnejšia v klasifikovaní triedy N3 (v grafe zodpovedá hodnote 3).

KUBICKÁ SVM KLASIFIKÁCIA




Obr. 32: SVM model 3 (na obrázku sú krížikom označené nesprávne klasifikované body)

Model 3									
True class	0	882	1	18	27		13	1	
1	13	1	6				9		
2	14		160	8			4		
3			25	15	8				
4			16	13	71	1			
5	48		6				53		
6			1						
9	1								
		0	1	2	3	4	5	6	9
		Predicted class							

Obr. 33: SVM model 3 – Confusion matrix, zobrazujúca počet pozorovaní klasifikovaných tried


Podľa kubickej SVM klasifikácie bola presnosť zostavenia predikčného modelu 83, 5 %. Výsledný model bol exportovaný do Workspace ako Cubic_Svm.mat.



Obr. 34: Confusion matrix – zobrazenie skutočne pozitívneho a falošne negatívneho pomeru kubickej SVM klasifikácie


Podľa grafu trénovaný model poskytol 94 % (0), 3 % (1), 86 % (2), 31 % (3), 70 % (4) a 50 % (5) správne klasifikovaných bodov (skutočne pozitívny pomer). Naopak, falošne negatívny pomer pri klasifikovaní jednotlivých klasifikovaných tried bol: 6 % (0), 97 % (1), 14 % (2), 69 % (3), 30 % (4), 50 % (5), 100 % (6) a 100 % (9).

COMPLEX TREE KLASIFIKÁCIA




Obr. 35: Complex Tree model (obrázok vpravo znázorňuje nesprávne klasifikované body)

Ďalším trénovaným klasifikátorom bol Complex Tree. Klasifikácia poskytla predikačný model len s presnosťou zostavenia na 78, 0 %. Výsledný model tréovania bol exportovaný do Workspace ako Complex_Tree.mat.




Obr. 36: Complex Tree model – Confusion matrix, zobrazujúca počet pozorovaní klasifikovaných tried



Obr. 37: Confusion matrix – zobrazenie skutočne pozitívneho a falošne negatívneho pomeru Complex Tree klasifikácie

Confusion matrix podľa Complex Tree klasifikácie vykazoval skutočne pozitívny pomer klasifikovania pre triedu 0 (92 %), 1 (10 %), 2 (58 %), 3 (27 %), 4 (60 %), 5 (48 %). Hodnoty pre falošne negatívny pomer: 0 (8 %), 1 (90 %), 2 (42 %), 3 (73 %), 4 (40 %), 5 (52 %), 6 (100 %), 9 (100 %).

kNN KLASIFIKÁCIA




Obr. 38: kNN model (na obrázku sú krížikom zaznačené nesprávne klasifikované body)

Model 5									
True class	0	856	14	4			68		
	1	1	7	1			20		
	2	2	22	108	2	2	50		
	3		2	37	3	3	3		
	4			27	20	53	1		
	5	1	17	4			85		
	6					1			
	9	1							
	Predicted class								
	0	1	2	3	4	5	6	9	

Obr. 39: kNN model – Confusion matrix, zobrazujúca počet pozorovaní klasifikovaných tried

V neposlednom rade bol natrénovaný model kNN s presnosťou zostavenia modelu na 78,6 %. V súvislosti s dobou tréovania dosiahol tento algoritmus najpriaznivejšej rýchlosti. Pracoval s Euklideovou vzdialenosťou, počet susedov k bol nastavený na hodnotu 1. Výsledný model bol exportovaný do Workspace ako Fine_kNN_model.mat.



Obr. 40: Confusion matrix – zobrazenie skutočne pozitívneho a falošne negatívneho pomeru kNN klasifikácie

Prvý stĺpec grafu (skutočne pozitívny pomer) dosiahol hodnôt 91 % (pre triedu 0), 24 % (pre triedu 1), 58 % (pre triedu 2), 6 % (pre triedu 3), 52 % (pre triedu 4) a 79 % (pre triedu 5). Falošne negatívny pomer (druhý stĺpec) nadobudol hodnôt 9 % (pre triedu 0), 76 % (pre triedu 1), 42 % (pre triedu 2), 94 % (pre triedu 3), 48 % (pre triedu 4), 21 % (pre triedu 5), a 100 % (pre triedy 6 a 9).

Tab. 5: Porovnanie tréovaných klasifikátorov z hľadiska presnosti, rýchlosti a doby tréovania

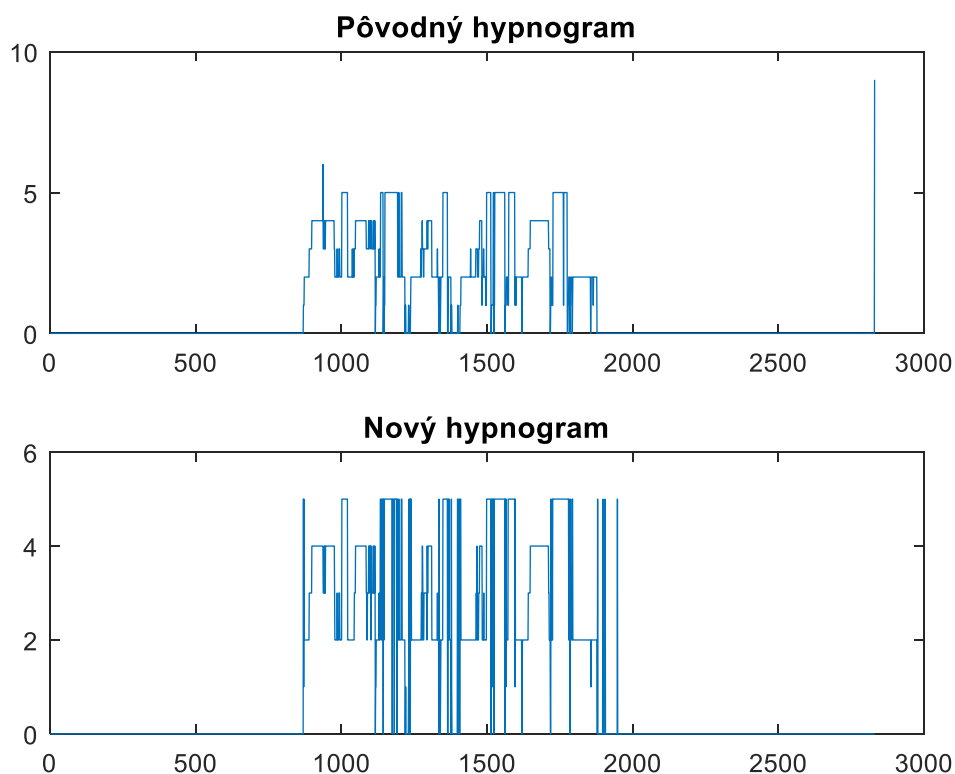
Klasifikátor	Presnosť zostavenia predikčného modelu (%)	Predikčná rýchlosť (obs/s)	Doba tréovania (s)
Lineárna SVM	90,6	150	151,60
Kvadratická SVM	89,9	27	220,82
Kubická SVM	83,5	28	214,34
Complex Tree	78,0	630	161,06
Fine kNN	78,6	47	86,723

6.1.2.2 TESTOVANIE KLASIFIKÁCIE

Výstupom testovania lineárnej SVM klasifikácie bol vektor TEST_DATA_LINEAR_SVM, ktorý obsahoval jednotlivé spánkové triedy hypnogramu. Príkaz pre testovanie klasifikácie zahŕňal jednak predikačný model i predikačné dáta, podľa ktorých bol zostavený daný model (bez vektoru hypnogramu).

```
TEST_DATA_LINEAR_SVM = Linear_Svm.predictFcn(prediction_data);
```


Obr. 41: Príkaz v matlabe pre testovanie lineárnej SVM klasifikácie



Obr. 42: Graf zobrazujúci pôvodný (nameraný) hypnogram a nový (klasifikovaný) hypnogram, vygenerovaný matlabom

Graf zobrazujúci výsledný hypnogram je popísaný osou y, na ktorej sú vynesené jednotlivé triedy hypnogramu v závislosti na časovej osi x. Keďže je databáza zastaralá, je nutné si previesť časovú os zo vzoriek na sekundy (1 vzorke hypnogramu (2831 celkom) by malo zodpovedať približne 3000 vzoriek surového EEG záznamu (8 490 000 celkom)). Keďže dĺžka epochy u EEG je 30 s a vzorkovacia frekvencia signálu predstavuje 100 Hz, po pre násobení dostaneme 3000 vz/s.

Prenásobením vzoriek hypnogramu (2831) a dĺžkou epochy (30), a následne podielom tohto súčinu číslom 3600 získame hodnotu približne 24 (vyjadrená v hodinách, celková dĺžka hypnogramu).



Obr. 43: Graf zobrazujúci pôvodný (modrý) a klasifikovaný (červený) hypnogram, vygenerovaný v matlabe (červené miesta označujú nezuhu medzi nameraným a klasifikovaným hypnogramom)

Grafy zobrazujú závislosť spánkových úrovní a časových vzoriek. Lineárna SVM klasifikácia poskytla slušné výsledky pre klasifikovanie hypnogramov (patričná zhoda medzi nameraným a klasifikovaným hypnogramom).

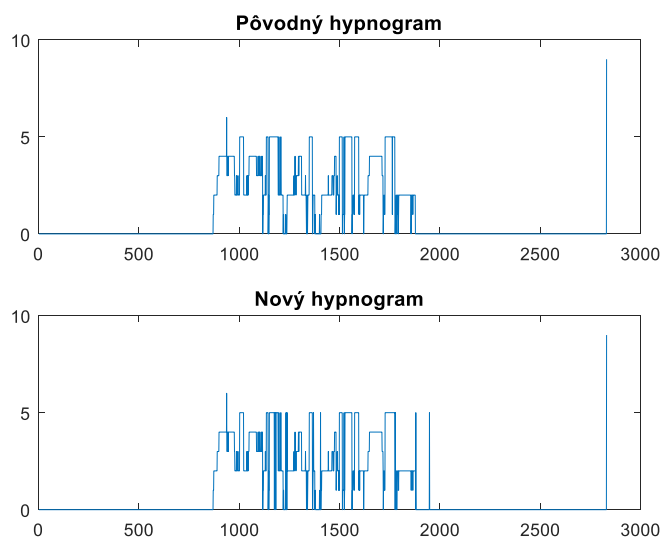
Tab. 6: Úspešnosť klasifikácie jednotlivých tried u lineárnej SVM

Epocha	W	N1	N2	N3	N4	R
Zhoda (-)	0,994	0,237	0,937	0,798	0,976	0,821
Zhoda (%)	99,4	23,7	93,7	79,8	97,6	82,1


Výstupom testovania kvadratickej SVM klasifikácie bol vektor
TEST_DATA_QUADRATIC_SVM.

```
TEST_DATA_QUADRATIC_SVM = Quadratic_Svm.predictFcn(prediction_data);
```

Obr. 44: Príkaz v matlabe pre testovanie kvadratickej SVM klasifikácie



Obr. 45: Graf zobrazujúci pôvodný (nameraný) hypnogram a nový (klasifikovaný) hypnogram, vygenerovaný matlabom



Obr. 46: Graf zobrazujúci pôvodný (modrý) a klasifikovaný (červený) hypnogram, vygenerovaný v matlabe (červené miesta označujú nezhodu medzi nameraným a klasifikovaným hypnogramom)

Testovanie kvadratickej SVM klasifikácie preukázalo vyššiu presnosť medzi nameraným a klasifikovaným hypnogramom.

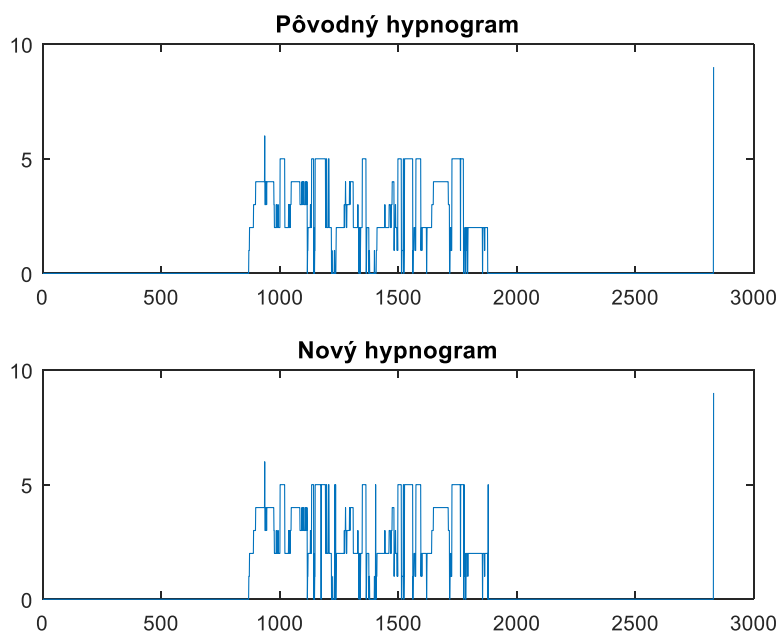
Tab. 7: Úspešnosť klasifikácie jednotlivých tried u kvadratickej SVM

Epocha	W	N1	N2	N3	N4	R
Zhoda (-)	0,995	0,949	0,989	1	1	0,964
Zhoda (%)	99,5	94,9	98,9	100	100	96,4

Výstupom kubickej SVM klasifikácie bol vektor TEST_DATA_CUBIC_SVM.


```
TEST_DATA_CUBIC_SVM = Cubic_Svm.predictFcn(prediction_data);
```

Obr. 47: Príkaz v matlabe pre testovanie kubickej SVM klasifikácie



Obr. 48: Graf zobrazujúci pôvodný (nameraný) hypnogram a nový (klasifikovaný) hypnogram, vygenerovaný matlabom

Najlepšiu klasifikáciu z rady SVM dosiahla kubická SVM klasifikácia s najvyššou presnosťou klasifikovania jednotlivých spánkových štádií. Detailnejší prehľad poskytuje zakreslenie pôvodného a klasifikovaného hypnogramu do jedného grafu, kde sú farebne odlíšené nesprávne klasifikované oblasti (červenou farbou).



Obr. 49: Graf zobrazujúci pôvodný (modrý) a nový (červený) hypnogram, vygenerovaný v matlabe (červené miesta označujú nezuhu medzi nameraným a klasifikovaným hypnogramom)

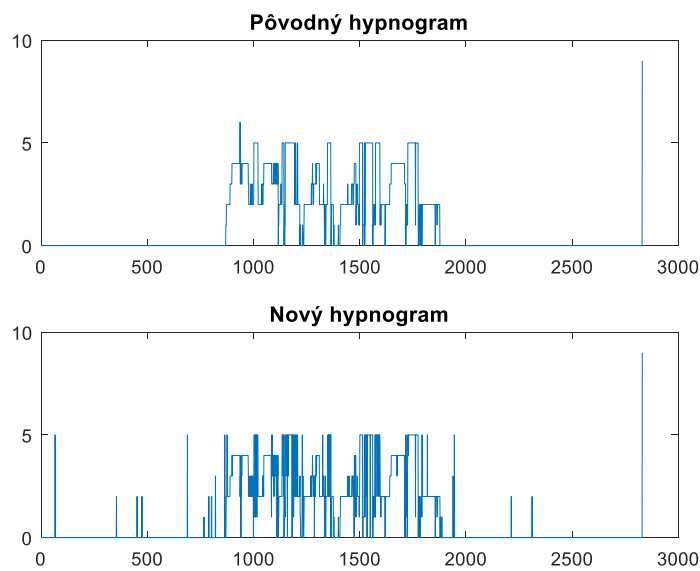
Tab. 8: Úspešnosť klasifikácie jednotlivých tried u kubickej SVM

Epocha	W	N1	N2	N3	N4	R
Zhoda (-)	0,996	1	0,995	1	1	0,977
Zhoda (%)	99,6	100	99,5	100	100	97,7


Výstupom Complex Tree klasifikácie bol vektor TEST_DATA_COMPLEX_TREE.

```
TEST_DATA_COMPLEX_TREE = Complex_Tree.predictFcn(prediction_data);
```

Obr. 50: Príkaz v matlabe pre testovanie Complex Tree klasifikácie



Obr. 51: Graf zobrazujúci pôvodný (nameraný) hypnogram a nový (klasifikovaný) hypnogram, vygenerovaný matlabom

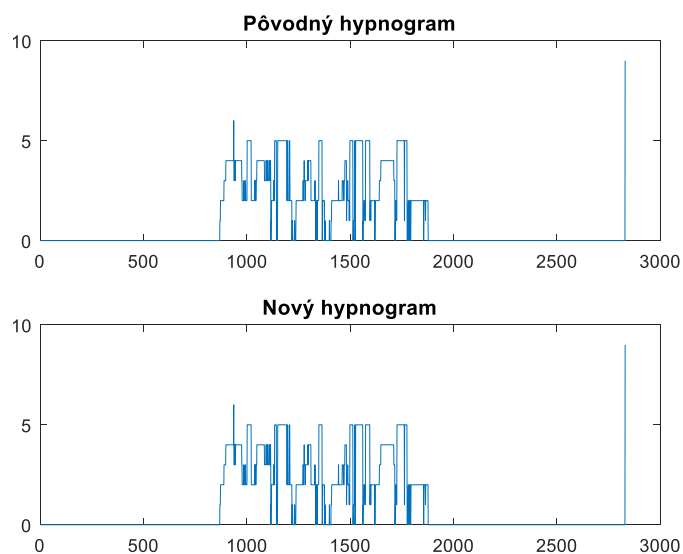


Obr. 52: Graf zobrazujúci pôvodný (modrý) a nový (červený) hypnogram, vygenerovaný v matlabe (červené miesta označujú nezuhu medzi nameraným a klasifikovaným hypnogramom)


Klasifikácia podľa Complex Tree nevykazovala presnosť a zhodu výsledkov medzi pôvodným a klasifikovaným hypnogramom. Tieto nepresnosti vykresľujú Obr.: 49 a Obr.: 50 (červené oblasti v grafe). Výstupom kNN klasifikácie bol vektor TEST_DATA_FINE_kNN.

```
TEST_DATA_FINE_kNN = Fine_kNN.predictFcn(prediction_data);
```

Obr. 53: Príkaz v matlabe pre testovanie kNN klasifikácie



Obr. 54: Graf zobrazujúci pôvodný(nameraný) hypnogram a nový (klasifikovaný) hypnogram, vygenerovaný matlabom



Obr. 55: Graf zobrazujúci pôvodný a klasifikovaný hypnogram

Úplné prekrytie hypnogramov, a teda najúspešnejšia klasifikácia hypnogramu nastala pri kNN klasifikácii so zhodou 100 %.

Tab. 9: Úspešnosť klasifikácie jednotlivých tried u Fine kNN

Epocha	W	N1	N2	N3	N4	R
Zhoda (-)	1	1	1	1	1	1
Zhoda (%)	100	100	100	100	100	100

Prvá časť práce poskytla pozitívne výsledky v súvislosti pre zostavenie hypnogramu. Automatický výpočet hypnogramu je možné použiť s pomerne úspešnou klasifikáciou jednotlivých tried. Najdlhší čas pre tréning klasifikácie spotrebovala kvadratická SVM klasifikácia (obdobná kubická SVM klasifikácia). Naopak, najrýchlejšiu klasifikáciu poskytla klasifikácia podľa kNN. 100% prekrytie hypnogramov bolo dosiahnuté pri kNN klasifikácii (najúspešnejšia klasifikácia). Na druhej strane, najnepriaznivejšie výsledky poskytol Complex Tree model (tento model nie je možné použiť pre správnu klasifikáciu).

Tab. 10: Počet jednotlivých epoch nameraného a klasifikovaného hypnogramu

Epocha	Celkový počet	W	N1	N2	N3	N4	R
Pôvodný hypnogram	2831	1885	59	373	94	203	215
Lineárna SVM	2831	1874	14	398	75	208	262
Kvadratická SVM	2831	1876	56	377	94	203	223
Kubická SVM	2831	1878	59	375	94	203	220
Fine kNN	2831	1885	59	373	94	203	215

Výsledky testovania SVM klasifikácie preukázali priaznivé klasifikovanie spánkových úrovní. Najlepšie skóre bolo dosiahnuté u kubickej SVM klasifikácie (99, 7 %). Kvadratická SVM klasifikácia sa ujala na 99, 3 % a lineárna SVM dosiahla presnosť klasifikovania spánkových úrovní na 96, 7 %.

Tab. 11: Úspešnosť klasifikácie jednotlivých klasifikátorov

Klasifikácia	Lineárna SVM	Kvadratická SVM	Kubická SVM	Fine kNN
Zhoda (počet epoch)	2737	2814	2822	2831
Nezhoda (počet epoch)	94	17	9	2831

Tab. 12: Úspešnosť klasifikácie jednotlivých klasifikátorov


Klasifikácia	Lineárna SVM	Kvadratická SVM	Kubická SVM	Fine kNN
Zhoda (-)	0, 967	0, 993	0, 997	1
Zhoda (%)	96, 7	99, 3	99, 7	100

S najnižšou presnosťou klasifikovania podľa lineárneho SVM bola klasifikovaná trieda N1. Najvyššia zhoda bola dosiahnutá u W, N2 a N4. Vysokú presnosť klasifikovania jednotlivých tried poskytla kvadratická a kubická SVM klasifikácia. Klasifikácia tried hypnogramu bola najúspešnejšia u kNN klasifikácie.

7 VYHODNOTENIE HYPNOGRAMU

Pri práci pre hodnotenie hypnogramov boli využité hypnogramy SC4002E0, SC4012E0 a SC4112E0. Po načítaní daného hypnogramu boli vypočítané jednotlivé parametre hypnogramu, ktoré udávajú rozdiely medzi optimálnymi a vypočítanými hodnotami. Všetky výpočty boli prevedené v matlabe. Vstupom pre jednotlivé výpočty boli vektory hypnogramov HYP_SC4002E0, HYP_SC4012E0 a HYP_SC4112E0.

Ako prvá bola vypočítaná celková doba spánku (Sleep_time_SC4012E0_h), vyjadrená v hodinách.



Obr. 56: Graf zobrazujúci zastúpenie celkového spánku v závislosti na dĺžke hypnogramu (SC4002E0)

```
Sleep_time_SC4002E0_h = (numel(Sleep_time_SC4002E0) * 30) / 3600;
```

Obr. 57: Výpočet celkovej doby spánku (hod)

Automatický výpočet bol prevedený pre celkový podiel REM / NonREM počas fázy spánku. Všetky výpočty boli vyjadrené jednak v percentách (NonREM_SC4002E0_per, REM_SC4002E0_per), a minútach (NonREM_SC4002E0_min, REM_SC4002E0_per). Pre každý hypnogram bola vypočítaná celková doba prebudenia (W_SC4002E0_min, W_SC4002E0_per).

```

NonREM_SC4002E0_min = (NonREM_SC4002E0_epoch * 30) / 60;
NonREM_SC4002E0_per = (NonREM_SC4002E0_epoch / numel(Sleep_time_SC4002E0)) *
    100;
REM_SC4002E0_min = (numel(REM_SC4002E0_epoch) * 30) / 60;
REM_SC4002E0_per = (numel(REM_SC4002E0_epoch) / numel(Sleep_time_SC4002E0)) *
    100;

```

Obr. 58: Výpočty pre celkový podiel REM / NonREM v hypnograme

Tab. 13: Porovnanie vypočítaných a optimálnych hodnôt parametrov hypnogramu (SC4002E0)

Parameter hypnogramu	Celková dĺžka spánku (hod)	Celkový podiel REM / NonREM		Celkový počet prebudení (%)
		REM (%)	NonREM (%)	
Optimálna hodnota	7 – 9	20 – 25	75 – 85	5
Vypočítaná hodnota	8, 4	21, 4	72, 3	6, 3

Tabuľka poukazuje na skutočnosť, že u spiaceho bola dosiahnutá optimálna dĺžka spánku pre hypnogram SC4002E0. Taktiež celkový podiel REM spánku a NonREM spánku vykazoval pozitívne hodnoty. V súvislosti s fázou prebudení došlo k minimálnej odchýlke v porovnaní s optimálnou hodnotou (s rozdielom 1, 3 %). Tieto mikroprebudení väčšinou nasledovali po REM fáze spánku.

Tab. 14: Parametre hypnogramu (SC4002E0)

Parameter hypnogramu	Celkový podiel REM (min)	Celkový podiel NonREM (min)	Celkový počet prebudení (min)
Optimálna hodnota	90 – 120	240 – 420	> 40
Vypočítaná hodnota	107, 5	364, 5	31, 5

Pre overenie, či vypočítaná hodnota daného parametra bude patriť do vopred definovaného intervalu optimálnych hodnôt bola uplatnená funkcia *ismember*. V prípade, že sa hodnota vyskytovala v tomto intervale, výstupom bola logická 1. V opačnom prípade, ak nebola táto hodnota v stanovenom rozmedzí, výstupom bola logická 0.

```

Chcek_REM_SC4002E0_per = ismember(round(REM_SC4002E0_per), REM_optimal_per);

```

Obr. 59: Porovnanie optimálnej a vypočítanej hodnoty REMU pomocou funkcie *ismember*

Tab. 15: Porovnanie vypočítaných a optimálnych hodnôt parametrov hypnogramu (SC4012E0)

Parameter hypnogramu	Celková dĺžka spánku (hod)	Celkový podiel REM / NonREM		Celkový počet prebudení (%)
		REM (%)	NonREM (%)	
Optimálna hodnota	7 – 9	20 – 25	75 – 85	5
Vypočítaná hodnota	8, 9	16, 5	79, 6	3, 9

Tabuľka hodnôt popisuje celkovú dĺžku spánku (Sleep_time_SC4012E0_h) takmer 9 hod. pre hypnogram SC4012E0. Celkový podiel REM (REM_SC4012E0_per) spánku (16, 5 %) vykazoval nižšiu hodnotu v porovnaní so stanovenou hodnotou. Percentuálne zastúpenie NonREM spánku (NonREM_SC4012E0_per) bolo vyjadrené ako 79, 6 %, fáza prebudení (W_SC4012E0_per) bola vyjadrená ako 3, 9 % celkovej doby spánku. Minútové vyjadrenie pre REM (REM_SC4012E0_min) bolo 88 min., pre NonREM (NonREM_SC4012E0_min) 424 min. a doba prebudení počas spánku bola 21 min.

Tab. 16: Parametre hypnogramu (SC4012E0)

Parameter hypnogramu	Celkový podiel REM (min)	Celkový podiel NonREM (min)	Celkový počet prebudení (min)
Optimálna hodnota	90 – 120	240 – 420	> 40
Vypočítaná hodnota	88	424	21

Tab. 17: Porovnanie vypočítaných a optimálnych hodnôt parametrov hypnogramu (SC4112E0)

Parameter hypnogramu	Celková dĺžka spánku (hod)	Celkový podiel REM / NonREM		Celkový počet prebudení (%)
		REM (%)	NonREM (%)	
Optimálna hodnota	7 – 9	20 – 25	75 – 85	5
Vypočítaná hodnota	5, 7	22, 1	77, 0	0, 9

Pre hypnogram SC4112E0 bola vyjadrená celková dĺžka spánku 5, 7 hod (mierny pokles v porovnaní s optimálnou dĺžkou spánku, Sleep_time_SC4112E0_h). Percentuálne vyjadrenie celkového podielu REMU (REM_SC4112E0_per) bolo 22,1 %, pre NonREM (NonREM_SC4112E0_per) bolo zastúpenie 77 % celkového spánku. Doba prebudení počas spánkového cyklu (W_SC4112E0_per) dosiahla 0,9 %.

Tab. 18: Parametre hypnogramu (SC4112E0)

Parameter hypnogramu	Celkový podiel REM (min)	Celkový podiel NonREM (min)	Celkový počet prebudení (min)
Optimálna hodnota	90 – 120	240 – 420	> 40
Vypočítaná hodnota	75,5	262,5	6

Minútové vyjadrenie pre REM spánok (REM_SC4112E0_min) bolo 75,5 min., pre NonREM (NonREM_SC4112E0_min) 262,5 min. a doba prebudení (W_SC4112E0_per) bola 6 min. celkovej doby spánku. Všetky vypočítané hodnoty vymedzuje interval optimálnych hodnôt parametrov hypnogramu (W_optimal_min, W_optimal_per, REM_optimal_min, REM_optimal_per, NonREM_optimal_min, NonREM_optimal_per).

Tab. 19: Porovnanie dĺžky prvého spánkového cyklu hypnogramu

Hypnogram	SC4002E0	SC4012E0	SC4112E0
Optimálna dĺžka (min)	70 – 120		
Vypočítaná dĺžka (min)	76,0	104,5	121,5

Pre porovnanie optimálnej dĺžky prvého spánkového cyklu bola vypočítaná dĺžka 76 min. pre hypnogram SC4002E0, 104,5 min. pre hypnogram SC4012E0 a 121,5 min. pre hypnogram SC4112E0. Optimálny interval hodnôt tohto parametra bol definovaný 70 – 120 min. podľa R&K.

8 Zhrnutie dosiahnutých výsledkov

Táto práca bola zameraná najmä na testovanie SVM klasifikácie. Princíp klasifikovania jednotlivých spánkových stavov spočíval vo výbere feature vektoru, ktorý bol definovaný spracovaním základných polysomnografických dát daného hypnogramu. Po prevedení PSD výpočtov pre EEG, EOG a EMG signály na konkrétnych frekvenčných pásmach, bol následne extrahovaný feature vektor. Pre výpočet výkonovej spektrálnej hustoty daného okna bol použitý Welchov odhad. Trénovanie algoritmu poskytlo predikačný model s vysokou presnosťou učenia. Testovali sa modely lineárnej SVM, kvadratickej a napokon kubickej SVM klasifikácie.

Všetky SVM modely použité pri testovaní vykazovali priaznivých výsledkov, a teda indikovali správnu klasifikáciu hypnogramu. Najvyššia úspešnosť bola preukázaná u kubickej SVM, naopak presnosť klasifikovania u lineárnej SVM bola znížená. Obsahom práce sú i vygenerované výsledky testovania modelov kNN a Complex Tree. Najlepšia klasifikácia sa osvedčila pri testovaní kNN predikačného modelu. Jediný klasifikátor Complex Tree nebol schopný určiť správnu klasifikáciu hypnogramu.

Za účelom sledovania kvality spánku na základe kvantitatívneho vyhodnotenia hypnogramu bolo dosiahnutých priaznivých výsledkov pre dané hypnogramy. Celková dĺžka spánku, celkový podiel REM / NonREM a celková doba prebudenia počas spánku bola sledovaná. Výpočty preukázali zanedbateľné odchýlky v porovnaní so stanovenými optimálnymi hodnotami.

Celý program pre klasifikáciu a hodnotenie hypnogramu je detailne popísaný v matlabe.

Záver

Klasické ambulantné klasifikovanie hypnogramu z polysomnografických dát je často zdĺhavým procesom, a preto sa neustále vyvíjajú a testujú nové klasifikačné algoritmy. Z medicínskeho hľadiska je hodnotenie hypnogramov dôležitým prvkom pri získavaní poznatkov o kvalite spánku pacienta, najmä v súvislosti so stanovením spánkovej poruchy a jej liečbou. Cieľom práce bol návrh a následné zostavenie hypnogramu na báze aplikovania zvoleného klasifikačného algoritmu. Súčasne bola práca zameraná na návrh a realizáciu metódy, ktorá umožní vyhodnotenie hypnogramu a spánkovej kvality spiaceho.

Úvod teoretickej časti spracováva problematiku snímania EEG, spánkoveho EEG a polysomnografie, vrátane hypnogramu. Súčasťou je detailný popis metód, ktoré boli využité pri klasifikácii hypnogramu a jeho vyhodnotení. Teoretický rozbor bol východiskovým bodom pri vypracovaní praktickej časti bakalárskej práce.

Celý program bol vypracovaný v programovacom jazyku matlab. Obsah prílohy tvoria tri samostatné kódy pre spracovanie a vyhodnotenie hypnogramu, doplnené vygenerovanými modelmi. Pre overenie konzistencie dát hypnogramov bola prevedená verifikácia dát. Súčasťou práce je tabuľkové vyjadrenie, ktoré preukázalo rôznu konzistenciu dát použitej databázy.

Program pre vytvorenie spánkoveho diagramu je členený na 3 fázy. Prvá fáza popisuje extrakciu feature vektoru, ktoré sa člení na výpočet PSD na konkrétnych PSG signáloch a segmentáciu signálu. Takto spracované dáta boli použité ako vstup pre zvolený klasifikátor. V druhej fáze je popísaný postup trénovania aktuálne zvoleného klasifikátoru, podľa ktorého bol zostavený predikačný model. Proces učenia algoritmu bol prevedený v LEARNING TOOLBOX, v matlabe. Posledná fáza programu bola venovaná testovaniu algoritmu pri použitom trénovanom modeli. Výstupom celej klasifikácie bol obraz nového hypnogramu. Dosiahnuté výsledky klasifikovania sú popísané v tabuľkách.

Zámerom druhej časti bakalárskej práce bol návrh a vypracovanie hodnotiacich metód hypnogramov. Pre rozsah práce bola táto časť obmedzená na konkrétnu metódu hodnotenia spánkovej architektúry. Program pre jeho vyhodnotenie spočíval v prevedení automatického výpočtu kvantitatívnych parametrov sledovaného hypnogramu. Tieto výpočty boli využité pri zhodnotení, do akej miery bola uplatnená kvalita spánku u spiaceho. Toto vyhodnotenie je doložené v tabuľkách, ktoré poskytujú porovnanie vypočítaných parametrov hypnogramu a štandardných hodnôt, udávajúcich optimálny spánok.

Zhodnoteniu dosiahnutých výsledkov oboch častí je venovaná posledná kapitola, ktorá stručne popisuje percentuálnu úspešnosť použitých klasifikačných metód a kvantitatívne vyhodnotenie hypnogramov.

Literatúra

- [1] AUGUSTYNEK, Martin. *Přístrojová zdravotnická technika II.: učební texty*. 1. vyd. Ostrava: VŠB – Technická univerzita Ostrava, 2011, 191, [17] s. ISBN 978-80-248-2446-8.
- [2] FABER, Josef. *Elektroencefalografie a psychofyziologie*. Vyd. 1. Praha: ISV, 2001, 170 s. Lékařství. ISBN 80-85866-74-9.
- [3] PENHAKER, Marek a Martin AUGUSTYNEK. *Zdravotnické elektrické přístroje 1*. 1. vyd. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2013, 411 s. ISBN 978-80-248-3107-7.
- [4] MORÁŇ, Miroslav. *Praktická elektroencefalografie*. 1. vyd. Brno: Institut pro další vzdělávání pracovníků ve zdravotnictví, 1995, 146 s. ISBN 80-7013-203-5.
- [5] CHOKROVERTY, Sudhansu, Robert J THOMAS a Meeta BHATT. *Atlas of sleep medicine*. 1st ed. Philadelphia, PA: Elsevier, Butterworth-Heinemann, 2005, viii, 362 p. ISBN 0750673982.
- [6] NEVŠÍMALOVÁ, Soňa, Jiří TICHÝ a Evžen RŮŽIČKA. *Neurologie*. 1. vyd. Praha: Galén, 2002, xiv, 368 s. ISBN 80-246-0502-3.
- [7] KOLÁŘ, R. *Lékařská diagnostická technika*, skripta předmětu Lékařská diagnostická technika. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2007. ISBN: ABM 07-91
- [8] Fyziologie spánku, [online][cit. 2016–01–18]. Dostupné z: <http://galenus.cz/clanky/zdravi/nervy-spanek>
- [10] Hypnograms. *Sleepdex* [online]. [cit. 2016-01-20]. Dostupné z: <http://www.sleepdex.org/hypnograms.htm>
- [11] Spánek. *Spánek - Nespavost* [online]. [cit. 2016-01-20]. Dostupné z: <http://www.spanek.psychoweb.cz>
- [12] VAUGHN, B. V. Technical Review of Polysomnography. *CHEST Journal* [online]. 2008-12-01, vol. 134, issue 6, s. 1310- [cit. 2015-05-19]. DOI: 10.1378/chest.08-0812. Dostupné z: <http://journal.publications.chestnet.org/article.aspx?doi=10.1378/chest.08-0812>
- [13] Klasifikace podle nejbližších sousedu Nearest Neighbour Classification [k-NN]. *Center for Machine Perception* [online]. 2001 [cit. 2016-01-20]. Dostupné z: <http://cmp.felk.cvut.cz/>
- [14] MathWorks. The Language of Technical Computing. *MATLAB* [online]. USA, 2017 [cit. 2017-05-22]. Dostupné z: <https://www.mathworks.com>
- [15] Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng C-K, Stanley HE, PhysioBank, PhysioToolkit, and PhysioNet: Components of a New

Research Resource for Complex Physiologic Signals. *Circulation* **101**(23):e215 – e220. 2000 [cit. 2017-05-22]. Dostupné z <http://circ.ahajournals.org/content/101/23/e215.full>

[16] SAYAD, Dr. Saed. Support Vector Machine - Classification (SVM). *An Introduction to Data Mining* [online]. 2017 [cit. 2017-05-22]. Dostupné z: <http://www.saedsayad.com>

[17] B Kemp, AH Zwinderman, B Tuk, HAC Kamphuisen, JJJ Oberyé. Analysis of a sleep-dependent neuronal feedback loop: the slow wave microcontinuity of the EEG. *IEEE-BME* **47**(9):1185-1194 (2000) [cit. 2017-06-27]. Dostupné z: <https://physionet.org/physiobank/database/sleep-edf/>

[18] SADEH, Avi. III. SLEEP ASSESSMENT METHODS. *MONOGRAPHS OF THE SOCIETY FOR RESEARCH IN CHILD DEVELOPMENT* [online]. 2015 [cit. 2017-06-27]. Dostupné z: <http://www.tau.ac.il/~sadeh/clinic/articles/Sadeh%20-%202015%20-%20Sleep%20assessment.pdf>

[19] MASTIN, Luke. TYPES AND STAGES OF SLEEP. *Sleep* [online]. 2013 [cit. 2017-06-27]. Dostupné z: <https://www.howsleepworks.com/what.html>

[20] AKERSTEDT, T., M. BILLIARD, M. BONNET, G. FICCA, L. GARMA, M. MARIOTTI, P. SALZARULO a J. SCHULZ. Awakening from sleep. *Sleep Medicine Reviews* [online]. 2013 [cit. 2017-06-27]. DOI: 10.1053/smr.2001.0202. ISSN Vol. 00, No.0, pp 1–19, 2002. Dostupné z: <https://www.idealibrary.com>

Použité zdroje obrázků

- [1] MLČOCH, Z. Artefakty na EEG záznamu - obrázky, dělení EEG artefaktů, [cit. 2016-01-18]. Dostupné z: <http://www.zbynekmlcoch.cz/informace/medicina/neurologie-nemoci-vysetreni/artefakty-na-eeg-zaznamu-obrazky-deleni-eeg-artefaktu>
- [2] VAUGHN, B. V. Technical Review of Polysomnography. *CHEST Journal* [online]. 2008-12-01, vol. 134, issue 6, s. 1310- [cit. 2015-05-19]. DOI: 10.1378/chest.08-0812. Dostupné z: <http://journal.publications.chestnet.org/article.aspx?doi=10.1378/chest.08-0812>
- [3] PENHAKER, Marek a Martin AUGUSTYNEK. *Zdravotnické elektrické přístroje I*. 1. vyd. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2013, 411 s. ISBN 978-80-248-3107-7.
- [4] Václav. Úvod do EEG - Významné frekvence, grafoelementy. *ZIVOTNI-ENERGIE.cz* [online]. 2007 [cit. 2016-01-20]. Dostupné z: <http://zivotni-energie.cz/uvod-do-eeg-vyznamne-frekvence-grafoelementy.html>
- [5] A quick primer on the technology behind our products: Feedback, Brainwaves and Entrainment. *MindMods (Consciousness Altering Technology)* [online]. 2014 [cit. 2016-01-20]. Dostupné z: http://www.mindmods.com/how_light_sound_mind_machines_biofeedback_neurofeedback_works.html
- [6] NeXus EEG cap. *Y.C.A.N. Australia* [online]. 2011 [cit. 2016-01-20]. Dostupné z: <http://www.ycanaustralia.com/NEXUS-EEG-CAP>
- [7] Where Do The Electrodes Go? *DIY tDCS Keeping Tabs Transcranial Direct Current Stimulation* [online]. 2012 [cit. 2016-01-20]. Dostupné z: <http://www.diytdcs.com/tag/1020-positioning/>
- [8] Childhood Adenotonsillectomy Trial. *National Sleep Research Resource* [online]. 2015 [cit. 2016-01-20]. Dostupné z: <https://sleepdata.org/datasets/chat/pages/manuals/polysomnography-reading-center/6-05-09-electrode-placement-measurement.md>
- [9] SAYAD, Dr. Saed. Support Vector Machine - Classification (SVM). *An Introduction to Data Mining* [online]. 2017 [cit. 2017-05-22]. Dostupné z: <http://www.saedsayad.com>
- [10] *Support vector machine* [online]. Wikipedia, 2017 [cit. 2017-06-27]. Dostupné z: https://en.wikipedia.org/wiki/Support_vector_machine

Zoznam príloh

Príloha na DVD – zdrojový kód vypracovaný pre štatisticko-numerický jazyk matlab (verzia R2016b).